

VŠB – Technická univerzita Ostrava

Fakulta strojní

Institut dopravy

Využití genetických algoritmů při řešení problémů
silniční dopravy

Genetical Algorithm for Road Transport Problems
Applications

Student:

Bc. Lukáš Pospěch

Vedoucí diplomové práce:

Ing. Teichmann Dušan, Ph.D.

Ostrava 2012

VŠB - Technická univerzita Ostrava
Fakulta strojní
Institut dopravy

Zadání diplomové práce

Student: **Bc. Lukáš Pospěch**
Studijní program: N2301 Strojní inženýrství
Studijní obor: 2301T003 Dopravní technika a technologie
Specializace: 20 Silniční doprava
Téma: **Využití genetických algoritmů při řešení problémů silniční dopravy**
Genetical Algorithm for Road Transport Problems Applications

Zásady pro vypracování:

Osnova práce:

1. Úvod.
2. Genetické algoritmy a jejich postavení v hierarchii optimalizačních metod.
3. Typologie problémů v odvětví silniční dopravy řešených genetickými algoritmy.
4. Obecné zásady při řešení problémů genetickými algoritmy.
5. Ukázka řešení optimalizačního problému z odvětví dopravy genetickým algoritmem.
6. Zhodnocení dosažených výsledků a jejich porovnání s výsledky dosaženými exaktní metodou.
7. Závěr.

Seznam doporučené odborné literatury:

HYNEK, J.: Genetické algoritmy a genetické programování. Praha: Grada Publishing. 2008. 182 s. ISBN 978-80-247-2695-3
ZELINKA, I.; OPLATKOVÁ, Z.; ŠEDA, M.; OŠMERA, P.; VČELAŘ, F.: Evoluční výpočetní techniky. Praha: BEN - technická literatura. 2008. 536 s. ISBN 978-80-7300-218-3

Formální náležitosti a rozsah diplomové práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.

Vedoucí diplomové práce: **Ing. Dušan Teichmann, Ph.D.**

Datum zadání: 16.12.2011

Datum odevzdání: 21.05.2012



doc. Ing. Vladimír Smrž, Ph.D.
vedoucí katedry



prof. Ing. Radim Farana, CSc.
děkan fakulty

Místopřísežné prohlášení studenta

Prohlašuji, že jsem celou diplomovou práci včetně příloh vypracoval samostatně pod vedením vedoucího diplomové práce a uvedl jsem všechny použité podklady a literaturu.

V Ostravě 11. 5. 2012

.....
podpis studenta

Prohlašuji, že

- jsem byl seznámen s tím, že na moji diplomovou práci se plně vztahuje zákon č. 121/2000 Sb. – autorský zákon, zejména §35 – užití díla v rámci občanských a náboženských obřadů, v rámci školních představení a užití díla školního a §60 – školní dílo.
- beru na vědomí, že Vysoká škola báňská – Technická univerzita Ostrava (dále jen VŠB-TUO) má právo nevýdělečně ke své vnitřní potřebě diplomovou práci užít (§35 odst. 3).
- souhlasím s tím, že jeden výtisk diplomové práce bude uložen v Ústřední knihovně VŠB-TUO k prezenčnímu nahlédnutí a jeden výtisk bude uložen u vedoucího diplomové práce. Souhlasím s tím, že údaje o diplomové práci budou zveřejněny v informačním systému VŠB-TUO.
- bylo sjednáno, že s VŠB-TUO, v případě zájmu z její strany, uzavřu licenční smlouvu s oprávněním užít dílo v rozsahu §12 odst. 4 autorského zákona.
- bylo sjednáno, že užít své dílo – diplomovou práci nebo poskytnout licenci k jejímu využití mohu jen se souhlasem VŠB-TUO, která je oprávněna v takovém případě ode mne požadovat přiměřený příspěvek na úhradu nákladů, které byly VŠB-TUO na vytvoření díla vynaloženy (až do jejich skutečné výše).
- beru na vědomí, že odevzdáním své práce souhlasím se zveřejněním své práce podle zákona č. 111/1998 Sb., o vysokých školách a o změně a doplnění dalších zákonů (zákon o vysokých školách), ve znění pozdějších předpisů, bez ohledu na výsledek její obhajoby.

V Ostravě 11. 5. 2012

..... Pospěch
podpis studenta

Jméno a příjmení autora práce: Lukáš Pospěch

Adresa trvalého pobytu autora práce: Chrustova 14 , Ostrava - Heřmanice

Rád bych poděkoval vedoucímu své diplomové práce Ing. Dušanu Teichmanovi, Ph.D. za potřebné informace, příjemnou spolupráci a za čas, který mi věnoval. Dále bych rád poděkoval panu Ing. Jiřímu Kociánovi za cenné rady ohledně softwaru Matlab.

ANOTACE DIPLOMOVÉ PRÁCE

POSPĚCH, L. Využití genetických algoritmů při řešení problémů silniční dopravy: diplomová práce. Ostrava: VŠB-Technická univerzita Ostrava, Fakulta strojní, Institut dopravy, 2012, 81 str. Vedoucí práce: Teichmann, D.

Diplomová práce se zabývá využitím genetických algoritmů při řešení problémů silniční dopravy. V úvodních částech diplomové práce jsou uvedeny základní informace týkající se genetických algoritmů. Pro vybrané typy úloh jsou následně sestaveny matematické modely, jejichž řešení je provedeno v optimalizačním softwaru Xpress-IVE a dále v softwaru Matlab, kde jsou úlohy vyřešeny pomocí genetických algoritmů.

V závěru diplomové práce jsou výsledky úloh získané pomocí genetických algoritmů porovnány s výsledky získanými exaktní metodou.

ANNOTATION OF MASTER THESIS

POSPĚCH, L. Genetical Algorithm for Road Transport Problems Applications: Master thesis. Ostrava: VSB-Technical University Ostrava, Faculty of Engineering, Institute of Transport, 2012, 81 pp. Thesis head: Teichmann, D.

This Master thesis deals with the use of genetic algorithms to solve problems of road transport. In the early parts of the thesis provides basic information on genetic algorithms. For selected types of tasks are then grouped together mathematical models, the solution is done in the optimization software Xpress-IVE and software in Matlab, where the tasks are solved using genetic algorithms.

At the end of the thesis are the results obtained with the task of genetic algorithms compared with those obtained by exact method.

OBSAH DIPLOMOVÉ PRÁCE:

Seznam použitých zkratk	9
1 Úvod	10
2 Genetické algoritmy	11
2. 1 Základní pojmy GA	11
2. 2 Genetické operátory	12
2. 2. 1 Selektce	12
2. 2. 2 Křížení	13
2. 2. 3 Mutace	14
2. 3 Činnost genetického algoritmu	14
2. 4 Výhody a nevýhody GA	15
2. 4. 1 Výhody	15
2. 4. 2 Nevýhody	16
3 Genetické algoritmy a jejich postavení v hierarchii optimalizačních metod	17
4 Typologie problémů řešených genetickými algoritmy	18
4. 1 Aplikace GA ve strojírenství	18
4. 2 Aplikace GA ve stavebnictví	19
4. 3 Aplikace GA v energetice	19
4. 4 Aplikace GA v silniční dopravě	20
5 Ukázka řešení optimalizačního problému v odvětví dopravy	22
5. 1 Formulace problému	22
5. 2 Matematický model	22
5. 3 Úloha o plánování rozvozu zásilek v dopravní síti č. 1	24
5. 4 Úloha o plánování rozvozu zásilek v dopravní síti č. 2	25
5. 5 Úloha o plánování rozvozu zásilek v dopravní síti č. 3	27
6 Úloha o plánování rozvozu zásilek v dopravní síti řešena exaktní metodou	29
6. 1. Postup řešení v programu Xpress-IVE	30
6. 2 Transformace matematického modelu úlohy č. 1 do textu programu pro optimalizační software Xpress-IVE	31
6. 3 Transformace matematického modelu úlohy č. 2 do textu programu pro optimalizační software Xpress-IVE	32
6. 4 Transformace matematického modelu úlohy č. 3 do textu programu pro optimalizační software Xpress-IVE	33

7 Úloha o plánování rozvozu zásilek v dopravní síti řešena genetickými algoritmy	34
7.1 Postup řešení programátorským způsobem prostřednictvím souboru typu M-file	34
7.2 Postup řešení uživatelským způsobem ve specializovaném toolboxu - Optimization Tool	37
7.2.1 Zadání fitness funkce a omezení	38
7.2.2 Grafy funkcí reprezentující průběh výpočtu.	38
7.2.3 Specifikace dalších parametrů	41
7.2.4 Řešení úlohy.	43
7.3 Řešení úlohy č. 1 - Optimization Tool	45
7.4 Řešení úlohy č. 2 - Optimization Tool	49
7.5 Řešení úlohy č. 3 - Optimization Tool	54
8 Výpočetní experimenty	59
8.1 Skupina experimentů č. 1	60
8.1.1 Úloha č. 2	61
8.1.2 Úloha č. 3	62
8.2 Skupina experimentů č. 2	63
8.2.1 Úloha č. 2	63
8.2.2 Úloha č. 3	64
8.3 Skupina experimentů č. 3	65
8.3.1 Úloha č. 2	66
8.3.2 Úloha č. 3	67
8.4 Skupina experimentů č. 4	68
8.4.1 Úloha č. 2	68
8.4.2 Úloha č. 3	69
8.5 Skupina experimentů č. 5	70
8.5.1 Úloha č. 2	71
8.5.2 Úloha č. 3	72
9 Zhodnocení dosažených výsledků a jejich porovnání s výsledky dosaženými exaktní metodou	75
10 Závěr	78
Seznam použité literatury	79
Seznam obrázků	81
Seznam tabulek	82

Seznam použitých zkratk:

GA – genetický algoritmus

GIS – geografické informační systémy

GPS – Global Positioning System

N – počet jedinců v populaci

NP – nelineární programování

OA – operační analýza

PSO – algoritmus rojení částic

a_i – zisk z přepravy zásilky $i=1..n$ [Kč]

b_i – parametr zásilky $i=1..n$ mající vztah ke kapacitě vozidla (hmotnost) [kg]

c_i – parametr zásilky $i=1..n$ mající vztah ke kapacitě vozidla (objem) [mm³]

f_i – fitness hodnota i -tého jedince

k – kapacita přepravního prostoru vozidla vyjádřena nosností [kg]

l – kapacita přepravního prostoru vozidla vyjádřena objemem [mm³]

n – počet zásilek

p_i – pravděpodobnost, s jakou bude i -tý jedinec vybrán [-]

x_i – bivalentní proměnná rozhodující zda zásilka $i=1..n$ bude, nebo nebude vybrána k přepravě

1 Úvod

Celá řada úloh z oblasti dopravy spadá do oblasti tzv. optimalizačních úloh nebo úloh optimalizace. Pojem optimalizace zahrnuje úlohy, jejichž podstatu lze zhruba shrnout následovně: jsou dány určité omezující podmínky, které stanovují obor přípustných řešení úlohy. Dále je dána tzv. účelová funkce. Podle této funkce jsou jednotlivým přípustným řešením přiřazeny jejich hodnoty, podle kterých usuzujeme kvalitu získaného řešení. Optimalizační úlohy se nejčastěji dělí podle charakteru oboru přípustných řešení na spojité a diskrétní a podle charakteru účelové funkce nebo omezujících podmínek na lineární a nelineární. Další dělení optimalizačních úloh je podle toho, zda jsou či nejsou řešitelné konvenčními metodami.

Mezi reálnými optimalizačními úlohami totiž existují takové typy problémů, které jsou konvenčními metodami (např. metodami OA) obtížně řešitelné nebo dokonce nejsou řešitelné vůbec.

Důvody tohoto jsou v zásadě tři:

- a) neexistuje vhodná konvenční metoda pro jejich řešení (např. situace v NP, kde neexistuje univerzální metoda, ale existují metody pouze pro určité typy úloh),
- b) optimální řešení se nepodaří najít, protože modely sestavené za účelem jejich řešení jsou značně rozsáhlé z hlediska počtu omezujících podmínek a proměnných,
- c) doba řešení optimalizační úlohy pomocí konvenčních metod překračuje dobu, kterou má řešitel pro řešení k dispozici.

Nastane-li některá z výše uvedených situací, používají se k řešení metody nekonvenční. Poměrně široké využití mají v této souvislosti i tzv. genetické algoritmy. Svou povahou spadají do tzv. heuristických metod, tj. úloh u kterých není zaručené nalezení optimality. Předložená diplomová práce je věnována právě problematice řešení optimalizačních úloh v silniční dopravě pomocí GA. Jejím cílem je zmapovat potenciál genetických algoritmů při řešení problémů silniční dopravy a na vybraném příkladě demonstrovat řešící postup za pomoci genetických algoritmů, získané výsledky srovnat s výsledky dosaženými exaktní metodou.

2 Genetické algoritmy

Vznik genetických algoritmů se datuje do 70. let dvacátého století. Genetické algoritmy byly poprvé představeny americkým fyzikem Johnem Hollandem. Jsou inspirovány evolučními procesy v přírodě popsané Charlesem Darwinem a J. G. Mengelem. Většina pojmů v GA jako jsou např. chromozóm, populace, gen jsou převzaty z biologie.

Genetické algoritmy jsou poměrně uznávaným nástrojem pro řešení optimalizačních problémů z různých oborů. Výpočetní postupy jsou založeny na principech genetiky a mechanismech přirozeného výběru. Používají se tam, kde přesné řešení úloh z praxe by systematickým prozkoumáváním trvalo téměř nekonečně dlouho [5].

2.1 Základní pojmy GA

K základním pojmům v genetických algoritmech patří:

- jedinec,
- populace,
- chromozóm,
- gen,
- fitness hodnota.

Jedinec je soustava znaků reprezentujících jedno řešení úlohy je zpravidla vyjádřen numerickým kódem. Každý jedinec je popsán fitness hodnotou.

Populace je skupina jedinců popsaných svými chromozómy v rámci jedné generace.

Chromozóm je řetězec znaků, jimiž je popsán každý jedinec z populace. Nese v sobě zakódované vlastnosti a chování. Skládá se ze sekvenčně uspořádaných genů, nejčastěji jde o řetězec nul a jedniček, ve kterých, je zakódována pozice jedince v prostoru možných řešení. Nemusí, ale vždy jít o prostý řetězec, jakým je např. celé číslo. Lze použít reálná čísla, matice, vektory i křivky. Chromozomy se skládají z genů.

Gen je elementární část chromozómu (při aplikaci algoritmů se již dále nedělí).

Fitness hodnota je číselné vyjádření kvality každého jedince. Nejčastěji jde o reálné číslo v rozsahu od 0 do 1, může to být také ale číslo z libovolného intervalu. Pro každý problém se sestavuje tzv. fitness funkce, která bude jako svůj výsledek dávat požadovanou

číselnou hodnotu. Funkce, na základě které se počítají fitness hodnoty, se nazývají fitness funkce [5].

2.2 Genetické operátory

U genetických algoritmů se používají 3 základní operátory, kterými jsou:

- selekce,
- křížení,
- mutace.

Uplatněním uvedených operátorů na populaci jedné generace vznikne nová generace. Proces aplikace genetických operátorů se neustále opakuje, dokud se v nově vytvořené generaci nevyskytne jeden, nebo více jedinců s požadovanými vlastnostmi, nebo není splněno jiné pravidlo pro zastavení evolučního vývoje [5].

2.2.1 Selektce

Selektce je první krok, který slouží k výběru potomků jedné generace, kteří se mohou stát rodiči v generaci nové. Existuje několik metod, jak tento krok provést. Většinou se při výběru jedinců přihlíží ke kvalitě jedince, tedy k fitness hodnotě jeho chromozómu.

Nejčastěji se při selekci používají tyto postupy výběru:

Vážená ruleta je jedna z prvních používaných metod, kde každý jedinec dostane na pomyslné ruletě takový podíl, který odpovídá jeho fitness hodnotě. Matematicky lze vyjádřit procentuální část rulety pro každého jedince následovně:

$$p_i = \frac{f_i}{\sum_{i=1}^N f_i}$$

p_i - pravděpodobnost, s jakou bude i -tý jedinec vybrán

f_i - fitness hodnota i -tého jedince

N - počet jedinců v populaci

Dle tohoto vztahu se vytvoří kruh rozdělený na N částí úměrných hodnotám p_i . S takto vytvořenou ruletou se pak provádí losování pro výběr každého dalšího rodiče.

Turnajová metoda je metoda, která také náhodně vybírá skupinu jedinců z populace. Daná skupina musí mít vždy minimálně dva jedince, tzn. že mohou být vybrány i větší skupiny. Vítězem turnaje ve skupině se stává jedinec s nejvyšší fitness hodnotou.

Ořezávání patří mezi další metodu selekce, kde se všichni jedinci seřadí podle své fitness hodnoty. Tato řada se pak dle libovolně zvoleného parametru rozdělí na dvě části. Z té části s nízkými fitness hodnotami nebude možné rodiče vybírat vůbec a z druhé části lze vybírat podle jakéhokoliv deterministického či náhodného pravidla [5].

2. 2. 2 Křížení

Je genetický operátor, který bezprostředně navazuje na selekci. Při křížení dochází ke vzniku nového jedince. Tento jedinec pak obsahuje smíšené charakteristiky všech svých rodičů.

V rámci procesu křížení dochází k vygenerování přirozeného čísla v intervalu $<1, n-1>$, kde n je počet genů v chromozómech a za vygenerovanou pozici dochází k záměně částí chromozómů. Nejjednodušší metoda této operace je jednobodové křížení, kdy se náhodně zvolí bod v chromozómu. Tato hranice rozdělí chromozóm na dvě části a ty se mezi potomky vymění. Křížení, ale může být i vícebodové. Příklad bodového křížení je uveden na obr. č. 1 (jednobodové křížení) a obr. č. 2 (vícebodové křížení).

Rodiče	Potomci
011 0111	1010111
101 1010	0111010

obr. č. 1 Jednobodové křížení [3]

Rodiče	Potomci
01 1011 1	0111011
10 1101 0	1010110

obr. č. 2 Vícebodové křížení [3]

Aplikace operátu křížení probíhá s určitou pravděpodobností literatura uvádí hodnotu 0,75 - 0,95 [5].

2. 2. 3 Mutace

Mutace obecně je změna v genetickém kódu jedince, která zapříčiní viditelnou nebo neviditelnou změnu v jeho struktuře. Mutace někdy přinese nečekané zlepšení, ale také může jedince vážně poškodit. Většina biologů věří, že právě mutace je oním hnacím motorem evoluce, v níž nové vlastnosti jinak než mutací vzniknout nemohou. I tato operace probíhá s určitou pravděpodobností, ale řádově menší přibližně pod hodnotu 0,05 [5]. Příklad operátoru mutace je uveden na obr. č. 3.

před mutací	po mutaci
0110111	1110011

obr. č. 3 Operátor mutace [3]

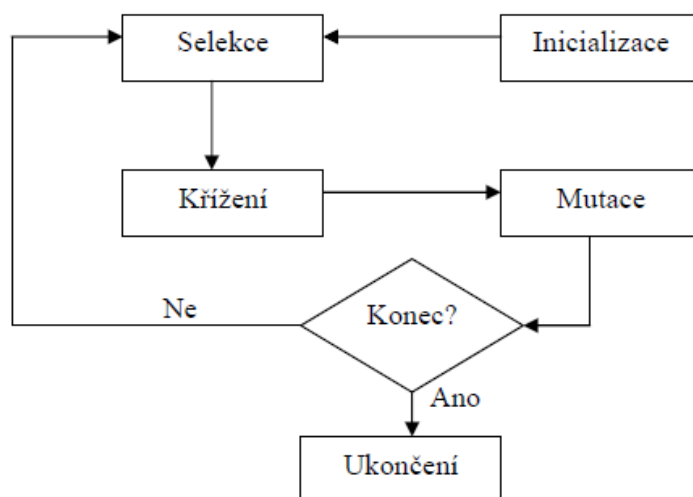
2. 3 Činnost genetického algoritmu

Vlastní činnost genetického algoritmu lze popsat následujícími kroky:

1. Inicializace – stanovení velikosti populace a náhodné vygenerování chromozómů pro všechny jedince. Defínování pravidel algoritmů, způsobu selekce jedinců, genetických operátorů a pravděpodobností jejich aplikace na jedince vybrané při selekci. Tím se vytvoří 1. generace a u každého jedince se stanoví fitness hodnota.
2. Aplikace genetických operátorů
 - aplikace operátoru selekce
 - aplikace operátoru křížení
 - aplikace operátoru mutace
3. Vyhodnocení nově vzniklé generace. Pokud vznikl jedinec splňující požadované vlastnosti, nebo bylo splněno pravidlo pro zastavení evolučního vývoje algoritmus končí.

4. Pokud není splněno pravidlo pro zastavení GA, náhrada stávající generace nově nalezenou a následuje návrat k bodu 2.

Schéma procesu činnosti GA je zobrazeno na obr. č. 4.



obr. č. 4 Schématické znázornění průběhu genetického algoritmu [3]

2. 4 Výhody a nevýhody GA

2. 4. 1 Výhody

GA umožňuje prozkoumání více než jednoho lokálního optima, a je zde větší možnost objevení globálního optimálního řešení. Schopnost nalézt globální optimum nebo řešení, které je svou kvalitou optimu blízké, je typickým znakem mnoha ostatních metaheuristických vyhledávacích technik (kam patří také genetické algoritmy).

GA umožňují současně manipulovat s více parametry. Z toho vyplývá, že tato vlastnost má schopnost předejít problému, kdy změnou pouze jednoho parametru se pouze jeden parametr zlepší, ale na úkor ostatních. Optimalizace, která nevede k těmto negativním projevům, se nazývá Paterovo optimum či nedominantní řešení.

Existuje zde mnoho variant GA, z nichž některé mají více schopností pro řešení problémů. Tyto genetické algoritmy se lehce přizpůsobují zadaným požadavkům, z čehož plyne velká flexibilita v průběhu použití. Tento atribut je pokládán za jeden z nejdůležitějších [4].

2. 4. 2 Nevýhody

Největším problémem získaných výsledků pomocí GA nebo ostatními pravděpodobnostními vyhledávacími metodami je ověření kvality konečného řešení. Tento problém lze zmírnit vícenásobným spuštěním algoritmu.

Převedení řešeného problému do chromozomu jedince není vždy snadnou záležitostí. Je-li zvolena nevhodná reprezentace, která není odolná vůči náhodným změnám, tak to může vést k fatálním chybám nebo k výsledkům, které nedávají smysl [4].

3 Genetické algoritmy a jejich postavení v hierarchii optimalizačních metod

Jak již bylo uvedeno v kapitole 2, spadají genetické algoritmy do skupiny tzv. evolučních algoritmů. Z hlediska nejobecnějšího členění patří evoluční algoritmy k algoritmům heuristickým. Heuristické algoritmy lze rozdělit na deterministické a stochastické.

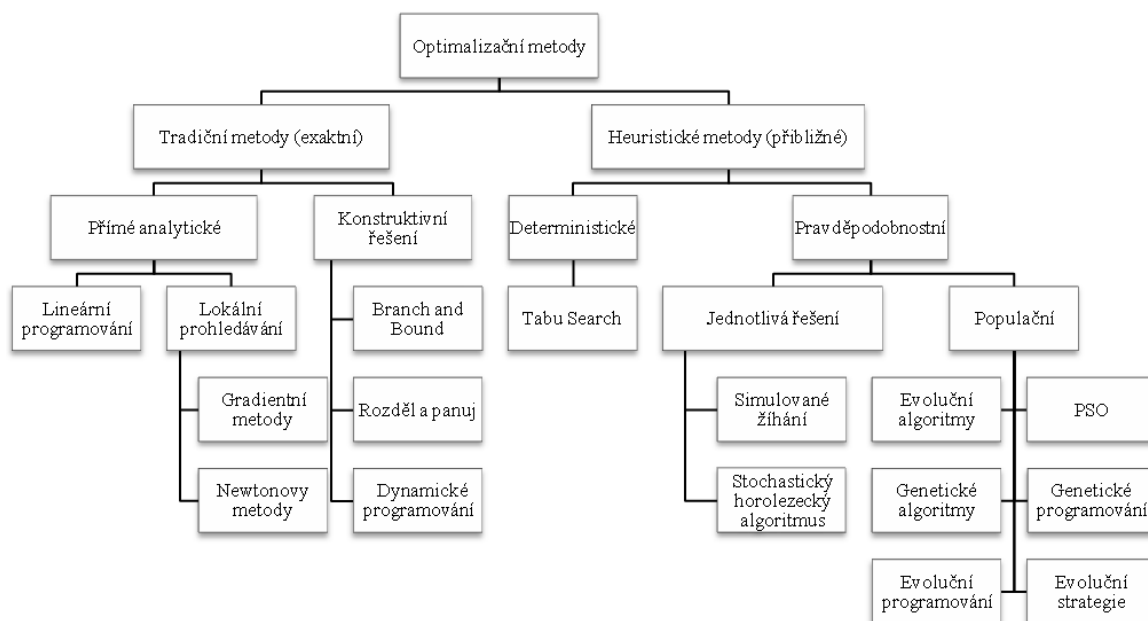
Stochastické heuristické metody se někdy také označují jako metaheuristiky, protože poskytují pouze obecný rámec a vlastní operace algoritmu je třeba zvolit (např. operace křížení a mutace u genetických algoritmů, operaci sousedství u simulovaného žíhání) v závislosti na zkoumaném problému.

Evoluční algoritmy lze obecně dle jejich strategie rozdělit do dvou tříd:

1. metody založené na bodové strategii (např. simulované žíhání, horolezecké algoritmy),
2. metody založené na strategii populace (např. genetické algoritmy).

Tyto metody se liší od klasických gradientních metod tím, že připouštějí s jistou pravděpodobností přijetí dočasně horšího řešení do další iterace za účelem opuštění lokálního optima [2].

Postavení genetických algoritmů v hierarchii optimalizačních metod, lze vidět na obr. č.5.



obr. č. 5 Hierarchie optimalizačních metod [2]

4 Typologie problémů řešených genetickými algoritmy

Genetické algoritmy jsou programovací techniky, jenž napodobují biologickou evoluci a užívají se jako nástroj k řešení problémů. Úspěšně se užívají na problémy, kde lokální optimalizační metody obvykle selhávají, nebo kde jejich aplikace není možná. U těchto algoritmů není vyžadován žádný specifický typ kritériální funkce, funkce nemusí být ani souvislá. Jediným požadavkem je požadavek na vyčíslení každého řešení. GA se ukázaly být výkonnou a úspěšnou strategií, která demonstruje schopnosti evolučních principů. Jejich aplikační možnosti jsou velmi široké a je možné je nalézt v celé řadě oblastí, jako například ve strojírenství, stavebnictví, energetice, informatice a v neposlední řadě v dopravě.

V této kapitole budou uvedeny aplikace genetických algoritmů do různých oblastí a především aplikace GA v silniční dopravě.

4.1 Aplikace GA ve strojírenství

Příkladem aplikace GA ve strojírenství je např. projekt firmy VÍTKOVICE ITS s.r.o., využívajícím genetickou optimalizaci u konstrukčního kusovníku, vytvořeného pro podporu práce konstruktéra. Konstrukční kusovník umožňuje konstruktérovi vytvářet detailní rozpis materiálu potřebného k výrobě vyvíjeného výrobku a zároveň ho uložit do podnikového informačního systému. Kusovník vzniká principiálně v konstrukci a je pak využíván například technologickými útvary, které do něj doplňují další specifické údaje.

Optimalizační část konstrukčního kusovníku plánuje způsob dělení tyčového materiálu tak, aby se ušetřilo co nejvíce výchozího polotovaru a snížily náklady na výrobu. Cílem optimalizace je minimalizovat počet použitých tyčí a dále maximalizovat zbytek z poslední tyče [8]. Uvedený problém, lze řešit také konvenčními metodami např. lineárním programováním. Důvod proč se lineární programování nevyužívá je jednoduchý. Použití lineárního modelu totiž vyžaduje definování možností dělení materiálů, z nichž je vybíráno nejvýhodnější řezné schéma. Množina řezných schémat však může být značně rozsáhlá a řešitel může snadno některou (třeba i tu nejvýhodnější) kombinaci opomenout do úlohy zařadit.

4. 2 Aplikace GA ve stavebnictví

Jedním s příkladů využití GA ve stavebnictví je optimalizace údržbových strategií mostovek. Mostovka je složka nosné konstrukce mostu, jejímž účelem je přenášet především účinky zatížení z mostního svršku na jeho hlavní nosnou konstrukci. S rychle rostoucími požadavky na údržbu mostů a s omezeným dostupným rozpočtem určeným na tuto údržbu, se stává důležitou otázkou optimalizace nákladů dlouhodobých údržbových strategií systému sítě mostů při současném požadavku na udržení jejich požadované funkčnosti. Celkové náklady údržby jsou funkcí počtu mostů a jejich úrovně degradace, plánovacího období a metod údržby. Ve výzkumu se k optimalizaci nákladů dlouhodobé údržby mostovek sítě mostů používají genetické algoritmy. Populace údržbových strategií se vyvíjí od jedné generace k další generaci užitím principů přirozeného výběru a přežití nejschopnějšího jedince [12].

4. 3 Aplikace GA v energetice

Další využití genetických algoritmů je při optimalizaci procesů v elektroenergetice. Aktuální vývoj v oblasti regulace spolehlivosti dodávky elektrické energie v energetických odvětvích, směřuje k zavádění systémových i zákaznických standardů. Postupná liberalizace trhu s elektrickou energií v zemích Evropské unie tento proces ještě urychluje. Distribuční společnosti se proto čím dál víc zajímají o hodnocení rizik vyplývajících ze zaváděných standardů.

Základem práce je minimalizace nákladů na technické ztráty v distribuční síti pomocí rekonfigurace distribuční sítě v závislosti na vybraných standardech. K optimalizaci byly využity dvě varianty moderních globálních optimalizačních technik ze skupiny evolučních algoritmů – genetických algoritmů. Kritériem optimalizace jsou náklady na ztráty a náklady na nedodávku elektrické energie.

Výsledky práce mohou být využity při procesu optimalizace distribučních sítí, při níž je spolehlivost zkoumané sítě reprezentována možnými reálnými náklady na penalizace na nedodávku elektrické energie [4].

4. 4 Aplikace GA v silniční dopravě

Příkladem využití GA v silniční dopravě je problém optimalizace tras svozu a rozvozu. Tato úloha má pro dopravce klíčový význam. Racionální plánování jízd může přinést značné úspory – udává se, že velikost úspory nákladů po zavedení prostředí umožňujícího optimalizaci tras vozidel činí v konkrétních podmínkách 5 až 20 %.

Na bázi GA je vyvinut např. software GA-GED VR, který umožňuje řešit vybrané modifikace základní úlohy okružních jízd (především s využitím genetických algoritmů) a v kombinaci s využíváním standardních geodat (GIS mapové podklady) [9].

Dalším využitím GA v silniční dopravě je optimalizace řízení toku energie v hybridních elektrických vozidel pomocí genetických algoritmů.

Hnací ústrojí hybridních elektrických vozidel, kombinující spalovací motor s pomocnou pohonnou jednotkou (elektromotor), nabízí zlepšení celkového dopadu vozidla na životní prostředí. Hlavní úkol řídicí jednotky je řízení toku energie, která rozděluje okamžitý příkon vozidla mezi spalovacím motorem a elektromotorem. Tímto je zajištěn efektivní provoz a snížení emisí.

Pomocí genetických algoritmů se identifikují hodnoty parametrů toku energie, které minimalizují náklady na funkci z hlediska spotřeby paliva a emisí. Více informací lze nalézt ve zdroji [10].

Dalším příkladem aplikace genetických algoritmů je jejich využití při inteligentním plánování tras. Síťové analýzy v geoprostorových informačních systémech (GIS) poskytují pomoc uživatelům při hledání optimální trasy, nalezení nejbližších zařízení a oblastí služeb. Pokročilou analýzu funkcí v GIS zajišťují heuristické algoritmy, které byly použity k hledání optimální cesty. Podrobnosti lze nalézt ve zdroji [11].

Genetický algoritmus můžeme dále využít pro optimalizaci autobusového dispečinku. Je zde řešen problém, který koordinuje příchod cestujících a zlepšuje úroveň služeb snížením průměrné čekací doby pro cestující. Více informací lze nalézt např. ve zdroji [7].

Pomocí genetických algoritmů byla dále navržena metoda AERARS. Slouží především pro potřeby krizových stavů (nehod) a vyhodnocuje nouzové požadavky. Nejčastěji se pomocí této metody řeší nalezení nejkratší cesty mezi zdrojem a cílem cesty. Umožňuje vyhledat při zadání potřebných informací nejbližší nemocnice, ambulance, policejní a hasičské stanice. Dále může být tato metoda použita pro hodnocení rizikových oblastí a tak mohou být přijata bezpečnostní opatření, která povedou ke snížení četnosti nehod v těchto rizikových oblastech. Pro lepší účinnost může být doplněna systémem GPS a satelitní technologií. Podrobnosti lze najít např. ve zdroji [6].

5 Ukázka řešení konkrétního optimalizačního problému v odvětví dopravy

V kapitole 5 bude pozornost věnována třem úlohám o plánování rozvozu zásilek a jejich obecnému řešení. Protože jedním z cílů je sledování efektivnosti GA ve srovnání se skutečným optimem, bude zvolena taková aplikace, která srovnání uvedeného typu umožňuje. Nejdříve bude sestaven model řešené úlohy (tzv. účelová funkce a soustava omezujících podmínek), následně budou navržena zadání řešena metodami umožňující nalezení optimálního řešení a genetickými algoritmy. Závěrem bude provedeno srovnání výsledků obou metod (vztažmo posouzena řešení dosažená GA).

5.1 Formulace problému

Je dána dopravní síť. Dopravce má možnost rozhodnout se, kterou zásilku z množiny n zásilek bude přepravovat, a kterou ne. Ve středisku je k dispozici obslužné vozidlo s kapacitou k (nosnost) a l (objem ložného prostoru). Pro každou zásilku $i = 1 \dots n$ je známa její hmotnost b_i , objem c_i a zisk z její přepravy a_i . Úkolem je rozhodnout, které z uvedených zásilek budou zařazeny do okružní jízdy konané za účelem obsluhy zákazníků, tak aby kapacita obslužného vozidla vyjádřená nosností a objemem přepravního prostoru nebyla překročena a současně, aby se maximalizoval zisk dopravce z přepravených zásilek.

5.2 Matematický model

Rekapitulace označení veličin pro potřeby matematického modelu.

a_i ... zisk z přepravy zásilky $i=1..n$,	[Kč]
b_i ... parametr zásilky $i=1..n$ mající vztah ke kapacitě vozidla (hmotnost),	[kg]
c_i ... parametr zásilky $i=1..n$ mající vztah ke kapacitě vozidla (objem),	[mm ³]
k ... kapacita přepravního prostoru vozidla vyjádřena nosností,	[kg]
l ... kapacita přepravního prostoru vozidla vyjádřena objemem,	[mm ³]
n ... počet zásilek.	

Za účelem řešení úlohy s využitím metod lineárního programování bude do úlohy zavedena skupina proměnných x_i . Definičním oborem proměnných budou hodnoty 0 a 1, tzn. půjde o bivalentní proměnné. Jestliže proměnná x_i nabude hodnoty 1, zásilka bude

vybrána k přepravě, jestliže proměnná x_i nabude hodnoty 0, zásilka nebude vybrána k přepravě.

Prvním krokem pro řešení úlohy optimalizačními metodami je sestava matematického modelu.

Účelová funkce modelu musí vyjadřovat vztah, podle kterého se vypočítá zisk z přepravy. Bude mít tedy tvar:

$$\sum_{i=1}^n a_i \cdot x_i \rightarrow \max .$$

Tvar účelové funkce je volen tak aby, nabude-li proměnná x_i hodnoty 1, výše zisku a_i se do hodnoty účelové funkce započítá, nabude-li proměnná x_i hodnoty 0, výše zisku a_i se do hodnoty účelové funkce nezapočítá.

Soustavou omezujících podmínek, je třeba zajistit následující skutečnosti:

- kapacita přepravního prostoru vozidla vyjádřena nosností nesmí být překročena,
- kapacita přepravního prostoru vozidla vyjádřena objemem nesmí být překročena,
- vymezit definiční obory proměnných zavedených do úlohy.

Podmínka zajišťující, že kapacita přepravního prostoru vyjádřená nosností nebude překročena, bude mít tvar:

$$\sum_{i=1}^n b_i \cdot x_i \leq k$$

Podmínka zajišťující, že kapacita přepravního prostoru vyjádřená objemem nebude překročena, bude mít tvar:

$$\sum_{i=1}^n c_i \cdot x_i \leq l$$

Obligatorní podmínky budou mít tvar:

$$x_i \in \{0,1\} \text{ pro } i = 1, \dots, n$$

Obecný matematický model bude mít v souhrnné podobě tvar:

$$\sum_{i=1}^n a_i \cdot x_i \rightarrow \max.$$

za podmínek:

$$\sum_{i=1}^n b_i \cdot x_i \leq k$$

$$\sum_{i=1}^n c_i \cdot x_i \leq l$$

$$x_i \in \{0,1\} \text{ pro } i = 1, \dots, n$$

Matematický model obsahuje v obecném tvaru $n + 2$ omezujících podmínek a n proměnných.

5.3 Úloha o plánování rozvozu zásilek v dopravní síti č. 1

Je dána dopravní síť. Dopravce má možnost rozhodnout se, kterou zásilku z 20-ti možných zásilek bude přepravovat, a kterou ne. Ve středisku je k dispozici obslužné vozidlo s kapacitou k . Pro každou zásilku $i = 1 \dots 20$ je známa její hmotnost b_i a zisk z její přepravy a_i . Úkolem je rozhodnout, které z uvedených zásilek budou zařazeny do okružní jízdy konané za účelem obsluhy zákazníků tak, aby kapacita obslužného vozidla vyjádřená nosností nebyla překročena a současně, aby se maximalizoval zisk dopravce z přepravených zásilek. V tab. č. 1 jsou zadány hodnoty pro tuto úlohu.

tab. č. 1 Zadány hodnoty pro úlohu o plánování rozvozu zásilek v dopravní síti č. 1

i	1	2	3	4	5	6	7	8	9	10
a_i [Kč]	1000	2500	1500	4000	9000	15000	6000	3000	1200	2000
b_i [kg]	50	80	120	140	30	200	150	160	90	80
i	11	12	13	14	15	16	17	18	19	20
a_i [Kč]	3500	4600	21000	600	6300	8400	16000	5500	12500	9900
b_i [kg]	120	170	10	20	70	190	140	80	40	100
k [kg]	1000									

Matematický model bude mít tvar:

$$1000 \cdot x_1 + 2500 \cdot x_2 + 1500 \cdot x_3 + 4000 \cdot x_4 + 9000 \cdot x_5 + 15000 \cdot x_6 + 6000 \cdot x_7 + 3000 \cdot x_8 + \\ + 1200 \cdot x_9 + 2000 \cdot x_{10} + 3500 \cdot x_{11} + 4600 \cdot x_{12} + 21000 \cdot x_{13} + 600 \cdot x_{14} + 6300 \cdot x_{15} + \\ + 8400 \cdot x_{16} + 16000 \cdot x_{17} + 5500 \cdot x_{18} + 12500 \cdot x_{19} + 9900 \cdot x_{20} \rightarrow \max.$$

za podmínek:

$$50 \cdot x_1 + 80 \cdot x_2 + 120 \cdot x_3 + 140 \cdot x_4 + 30 \cdot x_5 + 200 \cdot x_6 + 150 \cdot x_7 + 160 \cdot x_8 + 90 \cdot x_9 + 80 \cdot x_{10} + \\ + 120 \cdot x_{11} + 170 \cdot x_{12} + 10 \cdot x_{13} + 20 \cdot x_{14} + 70 \cdot x_{15} + 190 \cdot x_{16} + 140 \cdot x_{17} + 80 \cdot x_{18} + \\ + 40 \cdot x_{19} + 100 \cdot x_{20} \leq 1000$$

$$x_1 \in \{0,1\}, x_2 \in \{0,1\}, x_3 \in \{0,1\}, x_4 \in \{0,1\}, x_5 \in \{0,1\}, x_6 \in \{0,1\}, x_7 \in \{0,1\}, x_8 \in \{0,1\}, x_9 \in \{0,1\}, \\ x_{10} \in \{0,1\}, x_{11} \in \{0,1\}, x_{12} \in \{0,1\}, x_{13} \in \{0,1\}, x_{14} \in \{0,1\}, x_{15} \in \{0,1\}, x_{16} \in \{0,1\}, x_{17} \in \{0,1\}, \\ x_{18} \in \{0,1\}, x_{19} \in \{0,1\}, x_{20} \in \{0,1\}$$

5. 4 Úloha o plánování rozvozu zásilek v dopravní síti č. 2

Zadání úlohy č. 2 o plánování rozvozu zásilek je totožné se zadáním úlohy č. 1, avšak úloha je většího rozsahu. Dopravce má k dispozici 50 zásilek a nosnost obslužného vozidla je 1500 kg (nosnost byla zvýšena z důvodu, aby nedošlo k situaci, že množina přípustných řešení bude prázdná).

Úloha č. 2 je do předložené práce zavedena z důvodu sledování změn odchylky mezi optimálním řešením dosaženým exaktní metodou a nejlepším řešením dosaženým GA při zvyšujícím se rozsahu úlohy. V tab. č. 2 jsou zadány hodnoty pro výpočet této úlohy.

tab. č. 2 Zadané hodnoty pro úlohu o plánování rozvozu zásilek v dopravní síti č. 2

i	1	2	3	4	5	6	7	8	9	10
a _i [Kč]	1000	2500	1500	4000	9000	15000	6000	3000	1200	2000
b _i [kg]	50	80	120	140	30	200	150	160	90	80
i	11	12	13	14	15	16	17	18	19	20
a _i [Kč]	3500	4600	21000	600	6300	8400	16000	5500	12500	9900
b _i [kg]	120	170	10	20	70	190	140	80	40	100
i	21	22	23	24	25	26	27	28	29	30
a _i [Kč]	2000	1500	1600	3700	5000	9000	3000	2600	1200	900
b _i [kg]	40	60	110	100	35	180	120	60	20	30
i	31	32	33	34	35	36	37	38	39	40
a _i [Kč]	1500	1600	8000	1600	5300	3400	9100	1500	2500	7900
b _i [kg]	105	125	15	25	60	170	150	70	30	90
i	41	42	43	44	45	46	47	48	49	50
a _i [Kč]	900	8500	1700	3100	1000	5000	3400	1600	2200	1900
b _i [kg]	60	70	90	30	35	70	40	50	55	80
k [kg]	1500									

Vzhledem k rozsáhlosti vstupních údajů, nebude model pro variantu 2 rozepsán podrobně, ale pouze v symbolickém zápisu.

Matematický model bude mít tvar:

$$\sum_{i=1}^{50} a_i \cdot x_i \rightarrow \max.$$

za podmínek:

$$\sum_{i=1}^{50} b_i \cdot x_i \leq 1500$$

$$x_i \in \{0,1\} \text{ pro } i = 1, \dots, 50$$

5.5 Úloha o plánování rozvozu zásilek v dopravní síti č. 3

Zadání úlohy č. 3 o plánování rozvozu zásilek obsahuje tytéž vstupní údaje, jako úloha č. 1. Rozdíl spočívá v tom, že u každé zásilky známe kromě její hmotnosti, také její objem. Tedy omezení přepravovaných zásilek není dána jen nosností obslužného vozidla, ale také objemem. V tab. č. 3 jsou zadány hodnoty pro výpočet.

tab. č. 3 Zadané hodnoty pro úlohu o plánování rozvozu zásilek v dopravní síti č. 3

i	1	2	3	4	5	6	7	8	9	10
a_i [Kč]	1000	2500	1500	4000	9000	15000	6000	3000	1200	2000
b_i [kg]	50	80	120	140	30	200	150	160	90	80
c_i [mm ³]	400	100	300	250	1000	800	600	400	200	150
i	11	12	13	14	15	16	17	18	19	20
a_i [Kč]	3500	4600	21000	600	6300	8400	16000	5500	12500	9900
b_i [kg]	120	170	10	20	70	190	140	80	40	100
c_i [mm ³]	300	550	1100	200	500	700	800	700	1200	700
k [kg]	1000									
l [mm ³]	6000									

Matematický model bude mít tvar:

$$1000 \cdot x_1 + 2500 \cdot x_2 + 1500 \cdot x_3 + 4000 \cdot x_4 + 9000 \cdot x_5 + 15000 \cdot x_6 + 6000 \cdot x_7 + 3000 \cdot x_8 + \\ + 1200 \cdot x_9 + 2000 \cdot x_{10} + 3500 \cdot x_{11} + 4600 \cdot x_{12} + 21000 \cdot x_{13} + 600 \cdot x_{14} + 6300 \cdot x_{15} + \\ + 8400 \cdot x_{16} + 16000 \cdot x_{17} + 5500 \cdot x_{18} + 12500 \cdot x_{19} + 9900 \cdot x_{20} \rightarrow \max.$$

za podmínek:

$$50 \cdot x_1 + 80 \cdot x_2 + 120 \cdot x_3 + 140 \cdot x_4 + 30 \cdot x_5 + 200 \cdot x_6 + 150 \cdot x_7 + 160 \cdot x_8 + 90 \cdot x_9 + 80 \cdot x_{10} + \\ + 120 \cdot x_{11} + 170 \cdot x_{12} + 10 \cdot x_{13} + 20 \cdot x_{14} + 70 \cdot x_{15} + 190 \cdot x_{16} + 140 \cdot x_{17} + 80 \cdot x_{18} + \\ + 40 \cdot x_{19} + 100 \cdot x_{20} \leq 1000$$

$$400 \cdot x_1 + 100 \cdot x_2 + 300 \cdot x_3 + 250 \cdot x_4 + 1000 \cdot x_5 + 800 \cdot x_6 + 600 \cdot x_7 + 400 \cdot x_8 + 200 \cdot x_9 + \\ + 150 \cdot x_{10} + 300 \cdot x_{11} + 550 \cdot x_{12} + 1100 \cdot x_{13} + 200 \cdot x_{14} + 500 \cdot x_{15} + 700 \cdot x_{16} + 800 \cdot x_{17} + \\ + 700 \cdot x_{18} + 1200 \cdot x_{19} + 700 \cdot x_{20} \leq 6000$$

$$\begin{aligned}
& x_1 \in \{0,1\}, x_2 \in \{0,1\}, x_3 \in \{0,1\}, x_4 \in \{0,1\}, x_5 \in \{0,1\}, x_6 \in \{0,1\}, x_7 \in \{0,1\}, x_8 \in \{0,1\}, x_9 \in \{0,1\}, \\
& x_{10} \in \{0,1\}, x_{11} \in \{0,1\}, x_{12} \in \{0,1\}, x_{13} \in \{0,1\}, x_{14} \in \{0,1\}, x_{15} \in \{0,1\}, x_{16} \in \{0,1\}, x_{17} \in \{0,1\}, \\
& x_{18} \in \{0,1\}, x_{19} \in \{0,1\}, x_{20} \in \{0,1\}
\end{aligned}$$

Následující text bude věnován řešení definovaných úloh tak, aby bylo dosaženo optima a pomocí genetických algoritmů.

6 Úloha o plánování rozvozu zásilek v dopravní síti řešená exaktní metodou

V této kapitole bude pozornost věnována úlohám o plánování rozvozu zásilek v dopravní síti exaktní metodou. Konkrétně bude využito lineární programování, protože modely sestavené v kapitole 5 jsou lineárními modely. Jedná se o skupinu metod schopných nalézt optimální řešení dané úlohy. K vlastnímu řešení bude využit optimalizační software Xpress-IVE.

Aby bylo možno řešit uvedenou úlohu v softwaru Xpress-IVE, musí být sestavený matematický model přepsán do tvaru programu v jazyce MOSEL, se kterým optimalizační software Xpress-IVE pracuje.

6.1 Postup řešení v programu Xpress-IVE

Postup tvorby textu programu je demonstrován na úloze č. 1, postup je zřejmý z obr. č. 6, na kterém je zároveň vidět fragment pracovního prostředí použitého optimalizačního softwaru. Současně je na obr. č. 6 vidět výpis výsledků dané úlohy.

Každý program začíná slovem `model`

Druhý řádek obsahuje text

Následuje deklarační část (declaration), kde je třeba identifikovat všechny veličiny typu pole (každý symbol, který má nějaký index, je veličina typu pole např. a_i, x_i)

Definování účelové funkce např.: $\sum_{i=1}^n a_i \cdot x_i \rightarrow \max.$

příkaz vyjadřující hledaný extrém

Zápis podmínek např.: $\sum_{i=1}^n b_i \cdot x_i \leq k$ se запиše jako: $\text{sum}(i \text{ in } n) b(i) * x(i) \leq k$

Požadavek na výpis výsledků Příkaz `getobjval` vyvolá hodnotu účelové funkce a příkaz `getsol` je požadavek na výpis proměnných

Po kliknutí na ikonu `run model` nám program znázorní výsledky

Každé veličině typu pole, přiřadíme: of real – reálné číslo of mpvar – proměnná

Deklarační část ukončíme příkazem `end - declarations`

Definování polí: např. pro zisk z přepravy zásilky je to

Pokud je proměnná bivalentní použijeme příkaz `is_binary`, pokud celočíselná použijeme příkaz `is_integer`, pokud je proměnná nezáporná, není zapotřebí speciální příkaz

Ukončení programu

```

model rozvoz_zasilek
uses "mxxprs";

declarations
n=1..20
a:array(n)of real
b:array(n)of real
x:array(n)of mpvar
end-declarations

a::[1000,2500,1500,4000,9000,15000,6000,3000,1200,2000,
3500,4600,21000,600,6300,8400,16000,5500,12500,9900]
b::[50,80,120,140,30,200,150,160,90,80,
120,170,10,20,70,190,140,80,40,100]
k:=1000

sum(i in n)b(i)*x(i)<=k
forall (i in n)x(i)is_binary

zisk:=sum(i in n)a(i)*x(i)
maximize (zisk)

writeln("zisk je", " ",getobjval,"Kč")
writeln("vybrane zasilky")
forall(i in n)getsol(x(i))>0)writeln("x(",i,"")=",getsol(x(i)))

end-model
  
```

```

Run
View/Edit Clear

zisk je 107700Kč
vybrane zasilky
x(5)=1
x(6)=1
x(11)=1
x(13)=1
x(14)=1
x(15)=1
x(16)=1
x(17)=1
x(18)=1
x(19)=1
x(20)=1
  
```

obr. č. 6 Pracovní prostředí optimalizačního software Xpress-IVE

6.2 Transformace matematického modelu úlohy č. 1 do textu programu pro optimalizační software Xpress-IVE

Na základě zásad uvedených výše bude mít text programu, kterým bude řešen matematický model úlohy o plánování rozvozu zásilek v dopravní síti, tvar:

```
model rozvoz_zasilek_1
uses "mmxprs";

declarations

n=1..20
a:array(n)of real
b:array(n)of real
x:array(n)of mpvar

end-declarations

a::[1000,2500,1500,4000,9000,15000,6000,3000,1200,2000,
    3500,4600,21000,600,6300,8400,16000,5500,12500,9900]
b::[50,80,120,140,30,200,150,160,90,80,
    120,170,10,20,70,190,140,80,40,100]
k:=1000

sum(i in n)b(i)*x(i)<=k
forall (i in n)x(i)is_binary

zisk:=sum(i in n)a(i)*x(i)
maximize (zisk)

writeln("zisk je"," ",getobjval,"Kč")
writeln("vybrane zasilky")
forall(i in n|getsol(x(i))>0)writeln("x(",i,")=",getsol(x(i)))

end-model
```

Po kontrole syntaktické správnosti a spuštění řešení byly obdrženy následující výsledky:

zisk je 107700Kč
vybrane zasilky

$x(5)=1$	$x(11)=1$	$x(14)=1$	$x(16)=1$	$x(18)=1$	$x(20)=1$
$x(6)=1$	$x(13)=1$	$x(15)=1$	$x(17)=1$	$x(19)=1$	

Ze získaných výsledků vyplývá, že zisk je 107700 Kč a že k přepravě byly vybrány zásilky 5,6,11,13,14,15,16,17,18,19 a 20.

6.3 Transformace matematického modelu úlohy č. 2 do textu programu pro optimalizační software Xpress-IVE

```

model rozvoz_zasilek_2
uses "mmxprs";

declarations

n=1..50
a:array(n)of real
b:array(n)of real
x:array(n)of mpvar

end-declarations

a::[1000,2500,1500,4000,9000,15000,6000,3000,1200,2000,
3500,4600,21000,600,6300,8400,16000,5500,12500,9900,
2000,1500,1600,3700,5000,9000,3000,2600,1200,900,
1500,1600,8000,1600,5300,3400,9100,1500,2500,7900,
900,8500,1700,3100,1000,5000,3400,1600,2200,1900]
b::[50,80,120,140,30,200,150,160,90,80,
120,170,10,20,70,190,140,80,40,100,
40,60,110,100,35,180,120,60,20,30,
105,125,15,25,60,170,150,70,30,90,
60,70,90,30,35,70,40,50,55,80]
k:=1500

sum(i in n)b(i)*x(i)<=k
forall (i in n)x(i)is_binary

zisk:=sum(i in n)a(i)*x(i)
maximize (zisk)

writeln("zisk je"," ",getobjval,"Kč")
writeln("vybrane zasilky")
forall(i in n|getsol(x(i))>0)writeln("x(",i,")=",getsol(x(i)))

end-model

zisk je 165200Kč
vybrane zasilky
x(5)=1      x(17)=1      x(21)=1      x(33)=1      x(40)=1      x(47)=1
x(6)=1      x(18)=1      x(25)=1      x(35)=1      x(42)=1
x(13)=1     x(19)=1      x(26)=1      x(37)=1      x(44)=1
x(15)=1     x(20)=1      x(29)=1      x(39)=1      x(46)=1

```

Ze získaných výsledků vyplývá, že zisk je 165200 Kč a že k přepravě byly vybrány zásilky 5, 6, 13, 15, 17, 18, 19, 20, 21, 25, 26, 29, 33, 35, 37, 39, 40, 42, 44, 46 a 47

6.4 Transformace matematického modelu úlohy č. 3 do textu programu pro optimalizační software Xpress-IVE

```
model rozvoz_zasilek_3
uses "mmxprs";
```

```
declarations
```

```
n=1..20
a:array(n)of real
b:array(n)of real
c:array(n)of real
x:array(n)of mpvar
```

```
end-declarations
```

```
a::[1000,2500,1500,4000,9000,15000,6000,3000,1200,2000,
     3500,4600,21000,600,6300,8400,16000,5500,12500,9900]
b::[50,80,120,140,30,200,150,160,90,80,
     120,170,10,20,70,190,140,80,40,100]
c::[400,100,300,250,1000,800,600,400,200,150,
     300,550,1100,200,500,700,800,700,1200,700]
```

```
l:=6000
k:=1000
```

```
sum(i in n)c(i)*x(i)<=l
sum(i in n)b(i)*x(i)<=k
forall (i in n)x(i)is_binary
```

```
zisk:=sum(i in n)a(i)*x(i)
maximize (zisk)
```

```
writeln("zisk je", " ",getobjval,"Kč")
writeln("vybrane zasilky")
forall(i in n|getsol(x(i))>0)writeln("x(",i,")=",getsol(x(i)))
```

```
end-model
```

```
zisk je 92700Kč
```

```
vybrane zasilky
```

```
x(2)=1      x(6)=1      x(11)=1     x(15)=1     x(19)=1
x(4)=1      x(10)=1     x(13)=1     x(17)=1     x(20)=1
```

Ze získaných výsledků vyplývá, že zisk je 92700 Kč a že k přepravě byly vybrány zásilky 2, 4, 6, 10, 11, 13, 15, 17, 19 a 20.

7 Úloha o plánování rozvozu zásilek v dopravní síti řešená genetickými algoritmy

Zadané úlohy budou v této kapitole řešeny genetickými algoritmy, tedy metodou přibližnou, u které není prokazatelné, že získaný výsledek je optimálním řešením. Z tohoto důvodu bude každá z úloh řešena 10-ti experimenty tak, aby bylo docíleno co nejpřesnějších výsledků (při více experimentech existuje větší pravděpodobnost nalezení řešení blížíícího se svou hodnotou optimálního řešení). K řešení pomocí GA bude využit software Matlab. V software Matlab se dá zadaná úloha řešit dvojím způsobem a to:

- tzv. „programátorským způsobem“, vytvořením několika souborů typu M-file,
- tzv. „uživatelským způsobem“, prostřednictvím specializovaného toolboxu k řešení GA

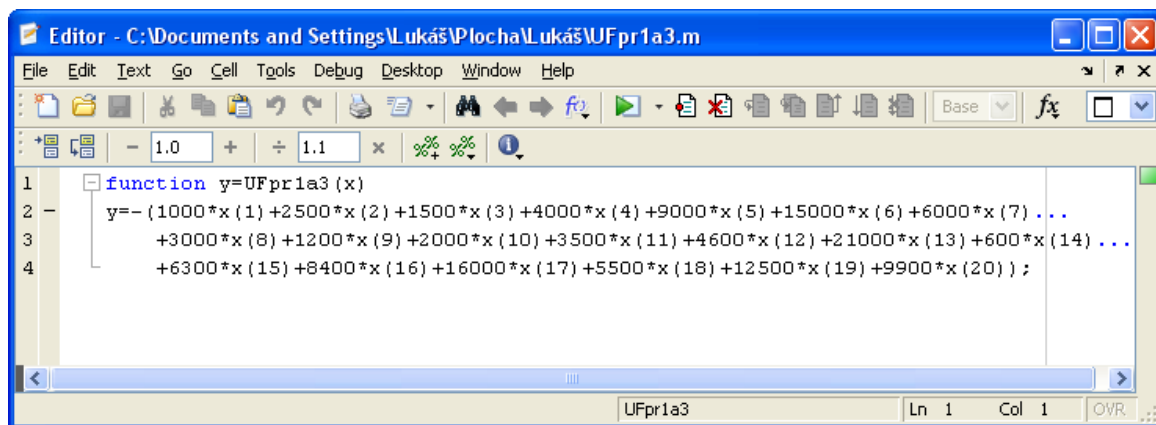
7.1 Postup řešení programátorským způsobem prostřednictvím souboru typu M-file

Po spuštění softwaru Matlab a nastavení adresáře, je potřeba vytvořit soubory typu M-file. Ty se vytvoří tak, že v levé horní části se vybere v nabídce: File - New - Figure, po té v okně Figure 1 se opět vybere: File - New - M-file.

U zadané úlohy je potřeba vytvořit tyto M-file soubory tři. První k vytvoření fitness funkce, druhý k vytvoření omezujících podmínek a třetí k samotnému výpočtu, kde se nastaví různé parametry požadované řešitelem.

1. M-file k vytvoření fitness funkce

Fitness funkce má za úkol maximalizovat zisk z přepravy zásilek, tedy daný M-file obsahuje jméno funkce (např. UFpr1a3), zápis funkce, kde jsou zisky z realizace jednotlivých přeprav (1000, 2500, ...) a samotné zásilky ($x(1)$, $x(2)$, ...). Jelikož GA hledá minimum funkce a v zadaném úkole je potřeba nalézt maximum funkce, tak je v účelové funkci znaménko mínus. Hledání maxima účelové funkce f je tedy pomocí znaménka mínus převedeno na hledání minima funkce ($-f$). Samotná funkce GA tedy nehledá maximum, ale minimum funkce. M-file k vytvoření fitness funkce je zobrazen na obr. č. 7.

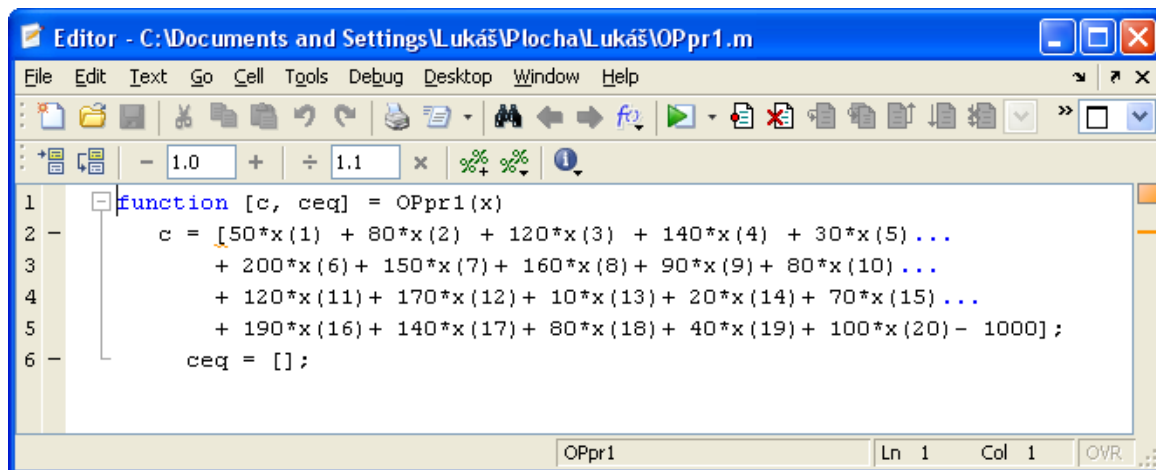


obr. č. 7 M-file k vytvoření fitness funkce

2. M-file k vytvoření omezujících podmínek

Omezující podmínkou u této úlohy je, že nosnost vozidla nesmí být překročena. Tedy daný M-file obsahuje jméno funkce (OPpr1), zápis funkce, kde jsou uvedeny hmotnosti jednotlivých zásilek (50, 80, ...), samotné zásilky (x(1), x(2), ...) a nakonec nosnost vozidla (1000).

M-file k vytvoření omezujících podmínek je zobrazen na obr. č. 8.




obr. č. 8 M-file k vytvoření omezujících podmínek

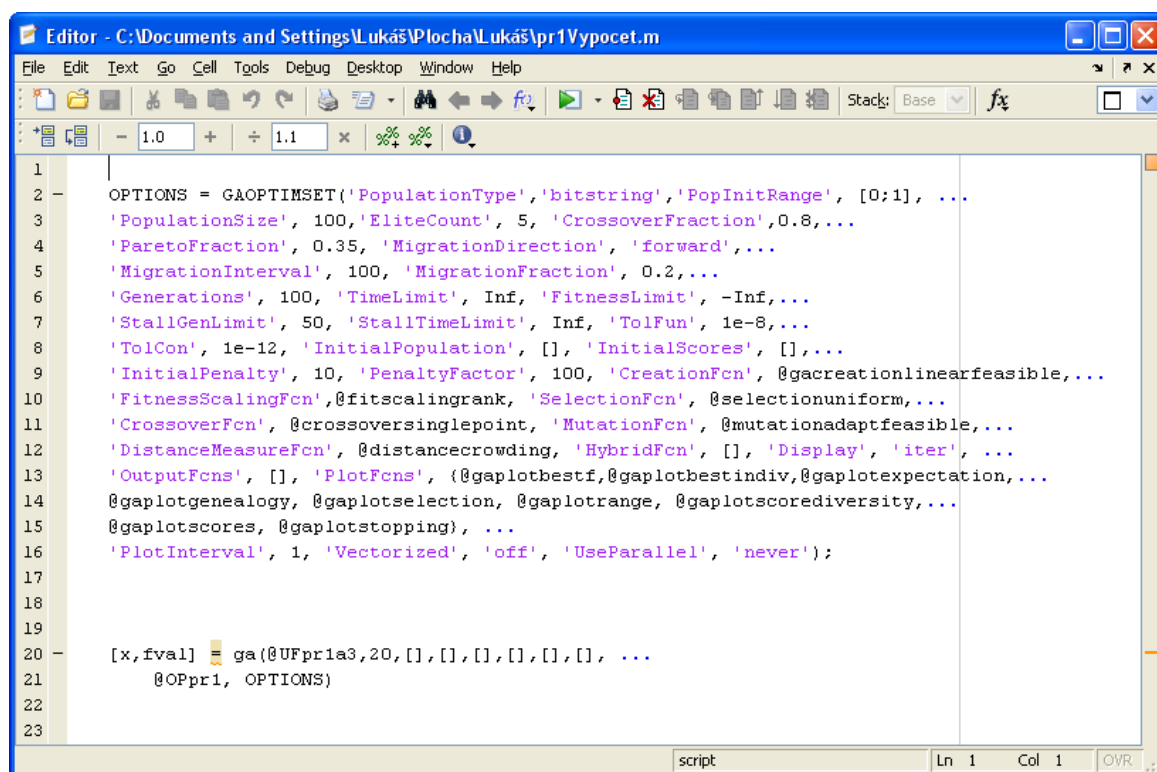
3. M-file přes který se provádí výpočet

Poslední a nejrozsáhlejší M-file soubor uvádí parametry řešitele, prostřednictvím kterých GA pracuje a také obsahuje samotný zápis, přes který se provádí výpočet. V první části M-file souboru je popsán Options k nastavení výpočtu genetických algoritmů. Úloha

obsahuje bivalentní proměnnou, tedy pro danou úlohu volíme Population type – Bit string, další parametry jsou převážně nastaveny standardně, až na několik výjimek. Např. velikost populace je standardně nastavena na hodnotu 20, pro potřeby experimentu je volena na hodnotu 100 z důvodu přesnějších výsledků. V dalších částech jsou nastaveny parametry selekce, křížení, mutace a v neposlední řadě grafické výstupy.

Ve spodní části je funkce, přes kterou se provádí výpočet. Je tvořena účelovou funkcí, neboli fitness funkcí, počtem proměnných, omezující podmínkou a nakonec zmíněným nastavením parametru řešitele (options).

Po kliknutí na ikonu Run  se spustí samotný výpočet. Výsledky se zapisují do pracovní plochy softwaru Matlab, kde se zobrazí nejen nejlepší dosažená fitness funkce, tedy nejvyšší dosažený zisk z přepravy zásilek, ale také seznam vybraných zásilek k přepravě. M-file přes který se provádí výpočet je zobrazen na obr. č. 9.



```

1
2 -  OPTIONS = GAOPTIMSET('PopulationType','bitstring','PopInitRange', [0:1], ...
3      'PopulationSize', 100,'EliteCount', 5, 'CrossoverFraction',0.8,...
4      'ParetoFraction', 0.35, 'MigrationDirection', 'forward',...
5      'MigrationInterval', 100, 'MigrationFraction', 0.2,...
6      'Generations', 100, 'TimeLimit', Inf, 'FitnessLimit', -Inf,...
7      'StallGenLimit', 50, 'StallTimeLimit', Inf, 'TolFun', 1e-8,...
8      'TolCon', 1e-12, 'InitialPopulation', [], 'InitialScores', [],...
9      'InitialPenalty', 10, 'PenaltyFactor', 100, 'CreationFcn', @gacreationlinearfeasible,...
10     'FitnessScalingFcn',@fitscalingrank, 'SelectionFcn', @selectionuniform,...
11     'CrossoverFcn', @crossoversinglepoint, 'MutationFcn', @mutationadaptfeasible,...
12     'DistanceMeasureFcn', @distancecrowding, 'HybridFcn', [], 'Display', 'iter', ...
13     'OutputFcns', [], 'PlotFcns', (@gaplotbestf,@gaplotbestindiv,@gaplotexpectation,...
14     @gaplotgenealogy, @gaplotselection, @gaplotrange, @gaplotscorediversity,...
15     @gaplotscores, @gaplotstopping), ...
16     'PlotInterval', 1, 'Vectorized', 'off', 'UseParallel', 'never');
17
18
19
20 -  [x,fval] = ga(@UFpr1a3,20,[],[],[],[],[],[], ...
21              @OPpr1, OPTIONS)
22
23

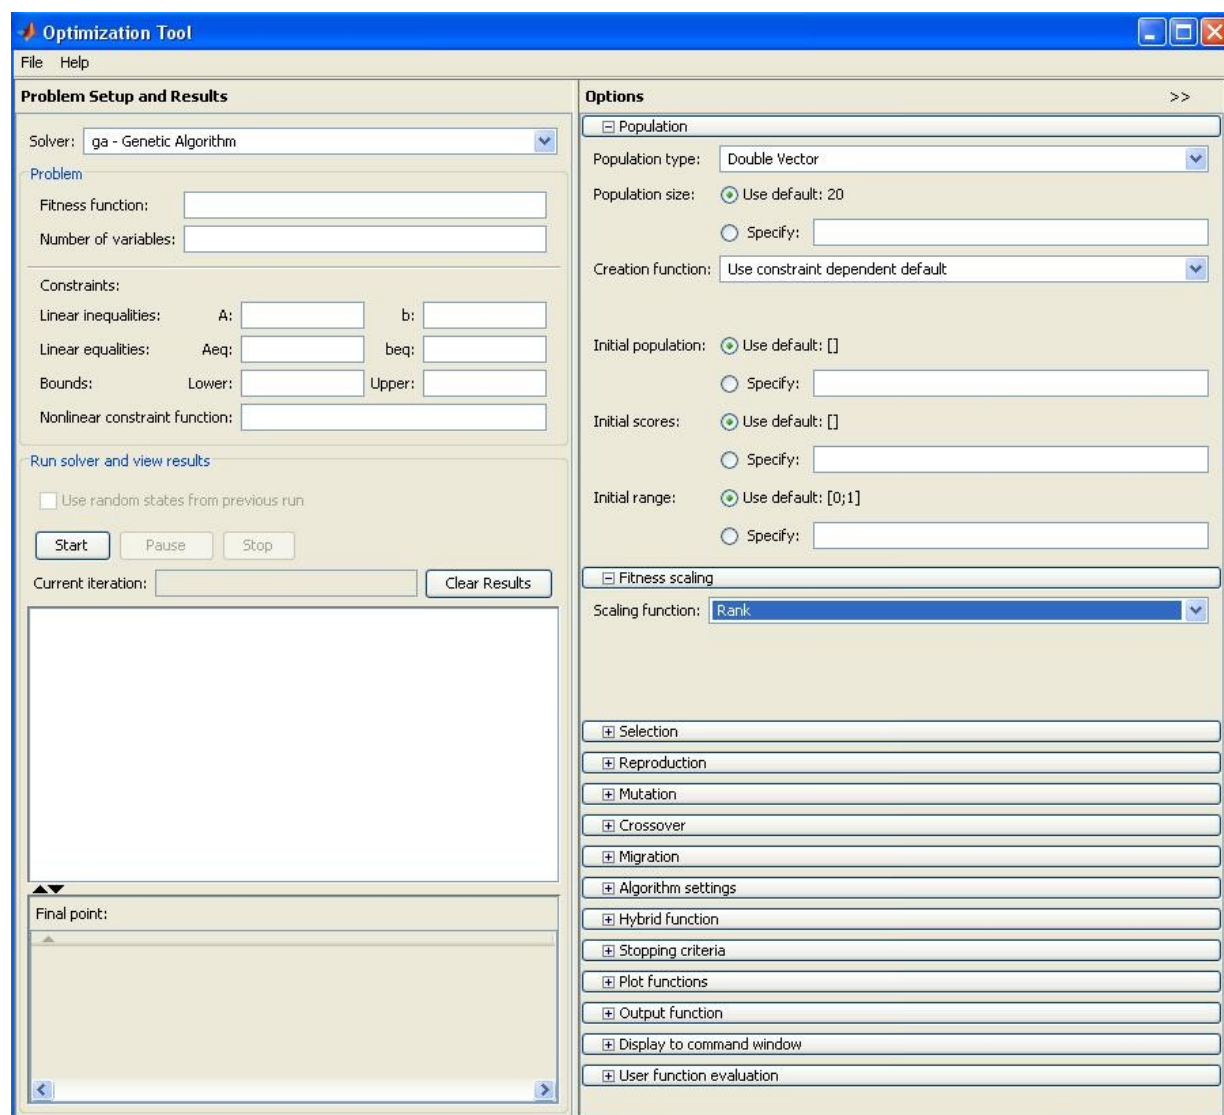
```

obr. č. 9 M-file přes který se provádí výpočet

7.2 Postup řešení uživatelským způsobem ve specializovaném toolboxu - Optimization Tool

Tato kapitola se bude zabývat popisem toolboxu Optimization Tool, který je součástí softwaru Matlab (R2010a), a zejména jeho částí ga - Genetic Algorithm.

Tento nástroj lze otevřít dvojím způsobem a to buď pomocí příkazu *gatool* z prostředí Matlabu, nebo přes tlačítko *Start – Toolboxes – Optimization – Optimization Tool* a po té je třeba vybrat ze *Solver* ga - Genetic Algorithm. Po otevření se zobrazí uživatelské (vstupní dialogové) okno, kde lze nastavovat různé parametry řešitele, volit kritéria pro zastavení výpočtu, vybírat grafické výstupy průběhu výpočtu, atd. (viz. obr. č. 10).



obr. č. 10 Okno nástroje gatool softwaru Matlab


7. 2. 1 Zadání fitness funkce a omezení

V levé části okna se zadává odkaz na fitness funkci ve tvaru *@fitnessf*, kde *fitnessf.m* je soubor typu M-file, který má za úkol vrátit hodnotu účelové funkce v zadaném bodě (pro zadaný vektor). Dále je nutné specifikovat počet nezávislých proměnných fitness funkce, které jsou reprezentovány jednotlivými chromozomy. Lze zadat i omezení na proměnné ve tvaru soustavy lineárních (ne)rovníc $A \cdot x = b$ (resp. $A \cdot x \leq b$). Rovněž je možné vymezit dolní a horní hranice hodnot, které mohou nezávislé proměnné nabývat ve tvaru vektoru. Je možnost použít nelineární omezení, kde je třeba ovšem vytvořit M-file s názvem např. *nelomez.m*, na který se v příslušném poli odkáže přes handle *@nelomez*. Funkce popsaná v tomto souboru musí vracet vektory **C** a **Ceq**, které odpovídají nelineárním omezením tvaru $C \leq 0$ a $Ceq = 0$ [3].

7. 2. 2 Grafy funkcí reprezentující průběh výpočtu

V další části okna lze zadávat, které funkce (resp. jejich průběh při výpočtu) uživatel žádá graficky znázornit:


- **Best fitness** – zobrazuje hodnotu fitness funkce nejúspěšnějšího jedince dané generace a průměrnou hodnotu fitness funkce v dané generaci (viz obr. č. 11).



obr. č. 11 Hodnota fitness funkce v jednotlivých generacích [3]


- **Expectation** – zobrazuje očekávaný počet potomků jednotlivých jedinců dané populace v závislosti na jejich „skóre“ (hodnotě fitness funkce).

- **Score diversity** – zobrazuje histogram četností jednotlivých hodnot fitness funkce v dané generaci (viz obr. č. 12).




obr. č. 12 Histogram skóre jednotlivých jedinců dané generace [3]

- **Stopping** – určuje aktuální úroveň kritérií při ukončení výpočtu (viz obr. č.13).




obr. č. 13 Úroveň kritérií pro ukončení výpočtu [3]

- **Best individual** – zobrazuje hodnotu nezávislých proměnných pro nejúspěšnějšího jedince dané generace.
- **Genealogy** – zobrazuje genealogii jedinců (černé linie označují elitní jedince, kteří přecházejí do následující generace, červené úsečky indikují jedince, kteří vznikli mutací a modré úsečky spojují jedince, kteří vznikli křížením, s jejich rodiči).
- **Scores** – určuje hodnoty fitness funkce pro jedince dané generace (viz obr. č.14).



obr. č. 14 Hodnota fitness funkce jednotlivých jedinců dané generace [3]

- **Max constraint** – znázorňuje maximální vzdálenost (míru nesplnění) nelineárního omezení pro danou generaci.
- **Distance** – zobrazuje průměrnou vzdálenost mezi jedinci v dané generaci.
- **Range** – znázorňuje minimální, maximální a průměrnou hodnotu fitness funkce v dané generaci (viz obr. č.15).
- **Selection** – zobrazuje histogram počtu potomků připadajících na jednotlivé třídy rodičů v dané generaci.



obr. č. 15 Hodnota fitness funkce nejlepšího, nejhoršího jedince a střední hodnota [3]

Do pole *Custom* lze jinak zadat libovolně definovanou kreslicí funkci formou Mfile. Pole *Plot interval* popisuje frekvenci vykreslování výše popsaných grafických výstupů [3].

7. 2. 3 Specifikace dalších parametrů

V pravé části vstupního dialogového okna lze zadávat další parametry výpočtu týkající se zejména funkce křížení, mutace a selekce. Lze využít již předdefinovaných funkcí nebo si opět formou M-file vytvořit vlastní návrhy. Najdeme zde možnosti zadávání následujících parametrů:

- **Population** - zadávají se parametry týkající se zvolené populace, tj. typ populace (*double*, *bit string*, *custom* - vlastní), velikost populace (počet jedinců), vytvářející funkci (*uniform* – pomocí rovnoměrného rozdělení, *custom* – vlastní vytvářející funkce), počáteční populaci, počáteční skóre a interval, z něhož se mají vybírat hodnoty pro počáteční populaci.
- **Fitness scaling** – zde zadáváme způsob, jakým budou jedinci dané populace hodnoceni (lze volit: *rank* – vychází z pořadí jedinců, *proportional* – proporcionalně odpovídá hodnotě fitness funkce, *top* – zadává se počet nejlepších

jedinců, kteří budou produkovat potomky, *shift linear* – zadává se konstanta očekávání pro nejlepšího jedince, *custom* – vlastní typ hodnocení).

- **Selection** – zde se zadává, jakým způsobem se budou vybírat rodiče pro vznik další generace (*stochastic uniform* – náhodný rovnoměrný výběr vzhledem k očekávání, *remainder* – deterministický výběr s užitím rulety, *uniform* – náhodný výběr z rovnoměrného rozdělení s ohledem na očekávání a počet rodičů, *roulette* – simuluje kolo rulety, kde jednotlivá pole odpovídají očekávání jednotlivých segmentů rodičů, *tournament* – náhodně vybere určitý počet jedinců a z nich toho nejlepšího, *custom* – vlastní funkce selekce).
- **Reproduction** – do pole *elite count* se zadává počet nejlepších jedinců, kteří automaticky přecházejí do další generace, a dále zde zadáváme, kolik procent jedinců bude kromě těchto elitních vytvořeno křížením (*crossover fraction*), zbývajících počet vznikne mutací.
- **Mutation** – zde zadáváme, jakým způsobem bude probíhat mutace (*Gaussian* – na základě Gaussova rozdělení, *uniform* – na základě rovnoměrného rozdělení, *adaptive feasible* – adaptivně s ohledem na dodržení omezení, *custom* – uživatelem definovaná mutace).
- **Crossover** – zde zadáváme způsob křížení (*scattered* – zobecněné křížení, *single point* – jednobodové křížení, *two point* – dvoubodové křížení, *intermediate* – vážený průměr rodičů, *heuristic* – uvažuje i účelovou funkci, *arithmetic* – vážený aritmetický průměr rodičů s ohledem na přípustnost, *custom* – uživatelem definované křížení).
- **Migration** – migrací se rozumí pohyb jedinců mezi dílčími populacemi. Nejlepší jedinci jedné dílčí populace, tak nahrazují nejhorší jedince druhé dílčí populace. Může jít o migraci dopřednou (*forward*), kdy jedinci přecházejí z n -té do $(n+1)$ -té populace nebo o migraci oběma směry (*both*), tj. i zpětně do $(n-1)$ -té populace. Počet přecházejících jedinců se zadává zlomkem *fraction* a frekvence migrace číslem *interval*.
- **Algorithm settings** – *initial penalty* – počáteční penalizace algoritmu (větší než 1), *penalty factor* – zvyšuje hodnotu parametru penalizace, není-li problém vyřešen s požadovanou přesností a omezení nejsou splněna (větší než 1).
- **Hybrid function** – zde lze nastavit další optimalizační funkci, která se spustí po ukončení genetického algoritmu (*fminsearch*, *patternsearch*, *fminunc*, *fmincon*).

- **Stopping criteria** – zde se zadávají kritéria pro ukončení výpočtu (počet generací, časový limit, fitness limit, počet generací, po které nedochází k významné změně fitness funkce, doba, po kterou nedojde k významné změně fitness funkce, kumulativní změna fitness funkce, maximální tolerance porušení nelineárního omezení).
- **Output function** – zde si můžeme nechat vypisovat historii algoritmu.
- **Display to command window** – zde se zadává požadavek, jaké informace řešitel požaduje zobrazovat v příkazovém okně (*iterative* – v každé iteraci výpočtu, *diagnose* – zobrazí se navíc další informace, *final* – zobrazí se důvod pro ukončení).
- **Vectorize** – vektorizace udává, zda se fitness funkce volá pro každého jedince zvlášť.

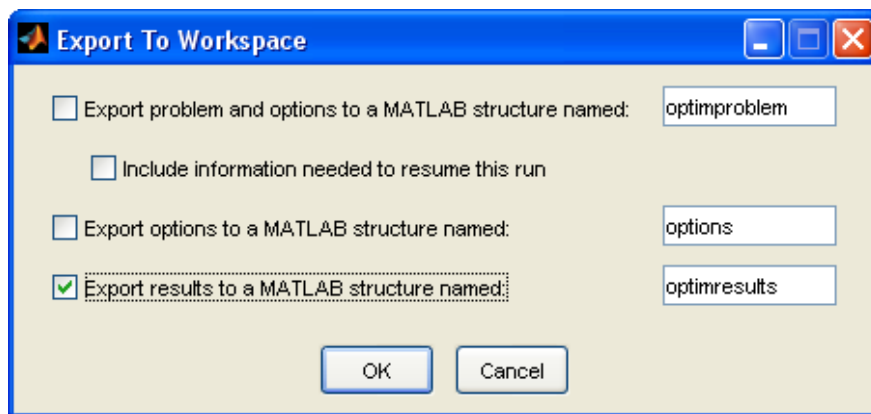
7. 2. 4 Řešení úlohy

Po zadání parametrů, funkcí a počtu nezávisle proměnných lze spustit samotný výpočet kliknutím na tlačítko *Start* v okně *Run solver and view results*. Pro získání co nejlepšího výsledku je třeba volit vyšší počet jedinců. Závisí to ovšem na výkonu počítače, který je k dispozici, neboť s přibývajícím počtem jedinců se výpočet zpomaluje. Je rovněž možné zadat limit fitness funkce pro ukončení výpočtu. Průběh samotného výpočtu lze pak sledovat pomocí uvedených grafických výstupů. Po ukončení výpočtu lze výsledky získat tím, že se exportují do pracovní plochy softwaru Matlab (viz obr. č. 16). V pracovní ploše je lze zobrazit příkazem *optimresults*, čímž se vypíší (viz. níže) hodnoty nejlepšího nalezeného řešení a hodnota fitness funkce.

`optimresults =`

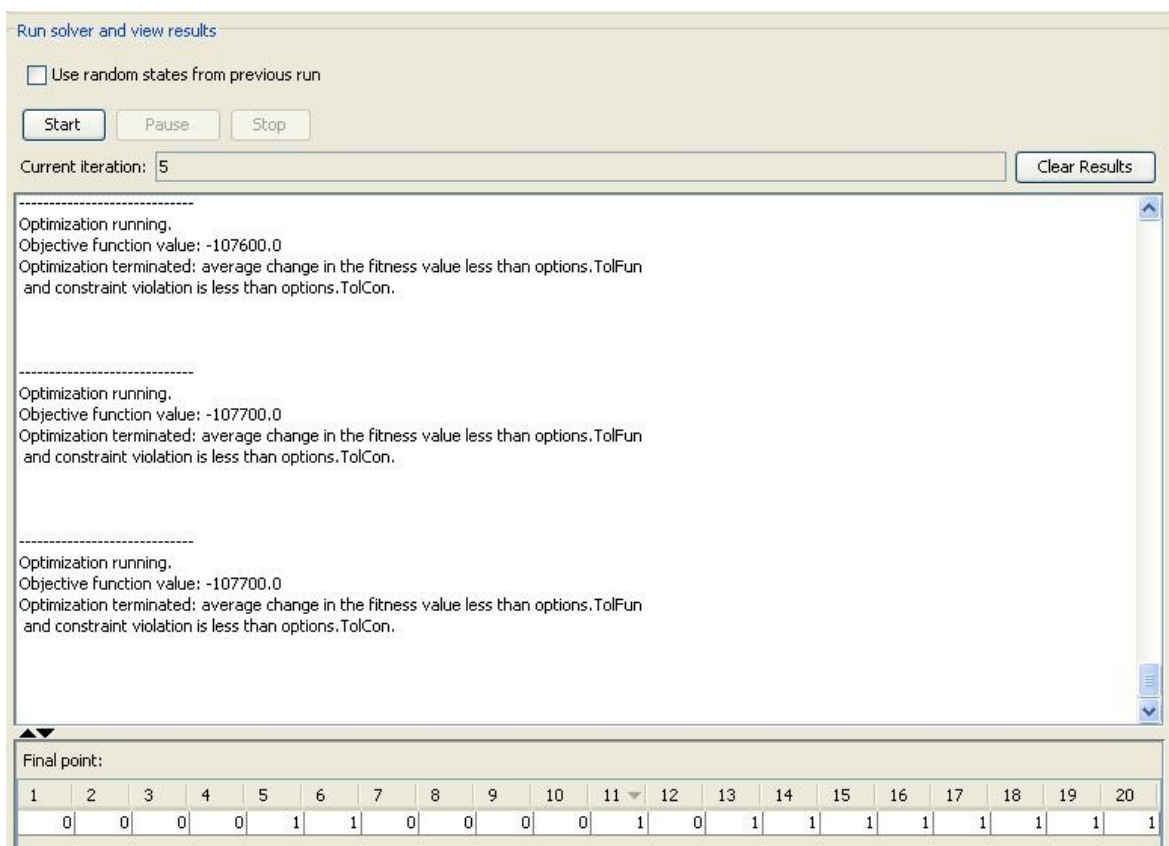
```

    x: [0 0 0 0 1 1 0 0 0 0 1 0 1 1 1 1 1 1 1]
    fval: -107700
    exitflag: 1
    output: [1x1 struct]
    population: [100x20 double]
    score: [100x1 double]
```



obr. č. 16 Export výsledků do pracovní plochy

Výsledky, lze také zobrazit přímo v toolboxu *Optimization Tool* v části *Run solver and view results*, kde se zobrazuje počet iterací a nejvyšší nalezena fitness funkce, tedy v našem případě dosažený zisk z přepravy. Ve spodní části okna, lze nalézt *Final point*, kde jsou zobrazeny vybrané proměnné. K těmto zásilkám jsou přiřazena čísla 0 a 1, kde číslo 0 znamená, že zásilka není vybrána k přepravě a číslo 1, že zásilka je vybrána k přepravě. Příklad zobrazení výsledků lze vidět na obr. č. 17.



obr. č. 17 Zobrazení výsledků

K výsledku, který je vidět v okně *Run solver and view results*, lze také zvlášť zobrazit do pracovní plochy hodnotu fitness funkce u jednotlivých iterací. Příkaz k provedení je v Options – Display to command windows – Level of display: Iterative. Zobrazení jednotlivých iterací u úlohy č.1 vypadá následovně:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	5300	-102200	0	0
2	10500	-105300	0	0
3	15700	-107600	0	0
4	20900	-107700	0	0
5	26100	-107700	0	1

Kde Generation znamená generace, f-count - funkční počet, Best f(x) – hodnota fitness funkce, max constraint – maximální omezení, Stall Generations – stálé generace.

V následujících pod kapitolách budou jednotlivé úlohy o plánování rozvozu zásilek řešeny se stejným nastavením v Optimization Tool. Pro základní skupinu experimentů bylo použito standartní nastavení, až na tyto výjimky:

PopulationType - bitstring, PopulationSize - 100, Selection - uniform,

Mutation - adaptive feasible a Crossover – single point.

7.3 Řešení úlohy č. 1 - Optimization Tool

V níže uvedené tab. č. 4 jsou uvedeny zvolené parametry výpočtu.

tab. č. 4 Zvolené parametry výpočtu

	Velikost populace	Druh selekce	Druh mutace	Druh křížení
Úloha č. 1	100	uniform	Adaptive feasible	single point

Výsledky experimentu č. 1:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	5300	-107700	0	0
2	10500	-107700	0	1
3	15700	-107700	0	2
4	20900	-107700	0	3
5	26100	-107700	0	4

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
0	0	0	0	1	1	0	0	0	0	1	0	1	1	1	1	1	1	1	1

Ze získaných výsledků vyplývá, že zisk je 107700 Kč, a že k přepravě byly vybrány zásilky: 5,6,11,13,14,15,16,17,18,19 a 20.

Výsledky experimentu č. 2:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	5300	-100400	0	0
2	10500	-104800	0	0
3	15700	-105800	0	0
4	20900	-105800	0	1
5	26100	-107600	0	0

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
0	0	0	1	1	1	0	0	0	0	0	1	0	1	1	1	1	1	1	1

Ze získaných výsledků vyplývá, že zisk je 107600 Kč, a že k přepravě byly vybrány zásilky: 4,5,6,13,15,16,17,18,19 a 20.

Výsledky experimentu č. 3:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	5300	-104800	0	0
2	10500	-106300	0	0
3	15700	-106300	0	1
4	20900	-106300	0	2
5	26100	-106300	0	3

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
0	1	0	0	1	1	1	0	0	1	0	0	1	1	1	0	1	1	1	1

Ze získaných výsledků vyplývá, že zisk je 106300 Kč, a že k přepravě byly vybrány zásilky: 2,5,6,7,10,13,14,15,17,18,19 a 20.

Výsledky experimentu č. 4:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	5300	-105800	0	0
2	10500	-107600	0	0
3	15700	-107600	0	1
4	20900	-107700	0	0
5	26100	-107700	0	1

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
0	0	0	0	1	1	0	0	0	0	1	0	1	1	1	1	1	1	1	1

Ze získaných výsledků vyplývá, že zisk je 107700 Kč, a že k přepravě byly vybrány zásilky: 5,6,11,13,14,15,16,17,18,19 a 20.

Výsledky experimentu č. 5:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	5300	-101900	0	0
2	10500	-105700	0	0
3	15700	-105700	0	1
4	20900	-105700	0	2
5	26100	-105700	0	3

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
1	0	0	0	1	1	1	0	0	0	0	0	1	1	1	1	1	0	1	1

Ze získaných výsledků vyplývá, že zisk je 105700 Kč, a že k přepravě byly vybrány zásilky: 1,5,6,7,13,14,15,16,17,19 a 20.

Výsledky experimentu č. 6:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	5300	-105800	0	0
2	10500	-105800	0	1
3	15700	-107100	0	0
4	20900	-107100	0	1
5	26100	-107100	0	2

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
1	1	0	0	1	1	0	0	0	0	0	0	1	0	1	1	1	1	1	1

Ze získaných výsledků vyplývá, že zisk je 107100 Kč, a že k přepravě byly vybrány zásilky: 1,2,5,6,13,15,16,17,18,19 a 20.

Výsledky experimentu č. 7:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	5300	-107100	0	0
2	10500	-107100	0	1
3	15700	-107100	0	2
4	20900	-107100	0	3
5	26100	-107100	0	4

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
1	1	0	0	1	1	0	0	0	0	0	0	1	0	1	1	1	1	1	1

Ze získaných výsledků vyplývá, že zisk je 107100 Kč, a že k přepravě byly vybrány zásilky: 1,2,5,6,13,15,16,17,18,19 a 20.

Výsledky experimentu č. 8:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	5300	-104300	0	0
2	10500	-107600	0	0
3	15700	-107600	0	1
4	20900	-107600	0	2
5	26100	-107600	0	3

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
0	0	0	1	1	1	0	0	0	0	0	0	1	0	1	1	1	1	1	1

Ze získaných výsledků vyplývá, že zisk je 107600 Kč, a že k přepravě byly vybrány zásilky: 4,5,6,13,15,16,17,18,19 a 20.

Výsledky experimentu č. 9:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	5300	-102200	0	0
2	10500	-105300	0	0
3	15700	-107600	0	0
4	20900	-107700	0	0
5	26100	-107700	0	1

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
0	0	0	0	1	1	0	0	0	0	1	0	1	1	1	1	1	1	1	1

Ze získaných výsledků vyplývá, že zisk je 107700 Kč, a že k přepravě byly vybrány zásilky: 5,6,11,13,14,15,16,17,18,19 a 20.


Výsledky experimentu č. 10:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	5300	-105700	0	0
2	10500	-107700	0	0
3	15700	-107700	0	1
4	20900	-107700	0	2
5	26100	-107700	0	3

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
0	0	0	0	1	1	0	0	0	0	1	0	1	1	1	1	1	1	1	1

Ze získaných výsledků vyplývá, že zisk je 107700 Kč, a že k přepravě byly vybrány zásilky: 5,6,11,13,14,15,16,17,18,19 a 20.

Grafické zobrazení shrnutí výsledků úlohy č. 1 je uvedeno na obr. č. 18.



obr. č. 18 Grafické zobrazení shrnutí výsledků úlohy č.1

Zhodnocení výsledků experimentu

Jak plyne z výsledků jednotlivých experimentů a také z obr. č. 18, nejlepších výsledků z pohledu účelové funkce bylo dosaženo v případě první úlohy, a to shodně ve čtyřech případech u experimentu č. 1, 4, 9, 10. Nejhorší výsledky byly získány v případě experimentu č. 5. Porovnáme-li získané výsledky s výsledky dosaženými lineárním programováním zjistíme, že v 60% experimentu nebylo dosaženo optimálního řešení. Je tedy nutno zdůraznit, že ani v případě tak malé úlohy nemusí dát GA optimální řešení není-li výpočet realizován opakovaně.

7.4 Řešení úlohy č. 2 - Optimization Tool

Pro řešení této úlohy byly zvoleny parametry, které jsou vypsány v tab. č. 5.

tab. č. 5 Zvolené parametry výpočtu

	Velikost populace	Druh selekce	Druh mutace	Druh křížení
Úloha č. 2	100	uniform	adaptive feasible	single point

Výsledky experimentu č. 1:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	5300	-146000	0	0
2	10500	-147500	0	0
3	15700	-152800	0	0
4	20900	-152800	0	1
5	26100	-154700	0	0

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25
0	1	0	0	1	0	0	0	0	0	0	0	1	1	1	0	1	1	1	1	1	1	0	1	1
26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50
0	0	1	1	0	0	0	1	1	1	0	1	0	1	1	0	1	0	1	1	1	1	0	0	0

Ze získaných výsledků vyplývá, že zisk je 154700 Kč, a že k přepravě byly vybrány zásilky: 2,5,13,14,15,17,18,19,20,21,22,24,25,28,29,33,34,35,37,39,40,42,44,45, 46 a 47.

Výsledky experimentu č. 2:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	5300	-131000	0	0
2	10500	-139500	0	0
3	15700	-147400	0	0
4	20900	-152500	0	0
5	26100	-153100	0	0

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25
0	0	0	0	1	1	1	0	0	0	0	0	1	1	0	0	1	1	1	1	0	0	1	0	1
26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50
0	0	0	0	1	0	0	1	1	0	0	1	0	1	1	0	1	0	1	1	1	1	0	0	0

Ze získaných výsledků vyplývá, že zisk je 153100 Kč, a že k přepravě byly vybrány zásilky: 5,6,7,13,14,17,18,19,20,23,25,30,33,34,37,39,40,42,44,45,46 a 47.

Výsledky experimentu č. 3:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	5300	-134100	0	0
2	10500	-146400	0	0
3	5700	-154500	0	0
4	20900	-158800	0	0
5	26300	-159400	0	0

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25
0	0	0	0	1	1	0	0	0	0	0	0	1	1	1	0	1	1	1	1	0	0	0	0	1
26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50
1	0	0	0	1	0	0	1	1	1	0	1	0	1	0	0	1	0	1	0	1	1	0	1	0

Ze získaných výsledků vyplývá, že zisk je 159400 Kč, a že k přepravě byly vybrány zásilky: 5,6,13,14,15,17,18,19,20,25,26,30,33,34,35,37,39,42,44,46,47,49 a 50.

Výsledky experimentu č. 4:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	5300	-141400	0	0
2	10500	-160400	0	0
3	15700	-161500	0	0
4	20900	-163100	0	0
5	26100	-163100	0	1

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25
0	0	0	0	1	1	0	0	0	0	0	0	1	1	1	0	1	1	1	1	1	0	0	0	1
26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50
0	0	0	1	1	0	0	1	1	1	0	1	0	1	1	0	1	0	1	0	1	1	1	1	0

Ze získaných výsledků vyplývá, že zisk je 163100 Kč, a že k přepravě byly vybrány zásilky: 5,6,13,14,15,17,18,19,20,21,25,39,30,33,34,35,37,39,40,42,44,46,47,48 a 49.

Výsledky experimentu č. 5:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	5300	-141300	0	0
2	10500	-151100	0	0
3	15700	-156300	0	0
4	20900	-159300	0	0
5	26100	-159300	0	1

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25
0	0	0	0	1	1	0	0	0	0	0	0	1	0	1	0	1	0	1	1	1	0	0	0	1
26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50
0	0	1	1	1	0	0	1	1	1	0	1	0	1	1	1	1	0	1	1	1	1	1	0	0

Ze získaných výsledků vyplývá, že zisk je 159300 Kč, a že k přepravě byly vybrány zásilky: 5,6,13,15,17,19,20,21,25,28,29,30,33,34,35,37,39,40,41,42,44,45,46,47 a 48.

Výsledky experimentu č. 6:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	5300	-144900	0	0
2	10500	-151500	0	0
3	15700	-153100	0	0
4	20900	-154100	0	0
5	26100	-154100	0	1

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25
0	0	0	0	1	0	0	0	0	1	0	0	1	1	1	0	1	1	1	1	1	0	0	1	1
26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50
1	0	0	1	0	0	0	1	1	1	0	1	0	1	1	0	1	0	1	1	0	1	0	0	0

Ze získaných výsledků vyplývá, že zisk je 154100 Kč, a že k přepravě byly vybrány zásilky: 5,10,13,14,15,17,18,19,20,21,24,25,26,29,33,34,35,37,39,40,41,42,44,45 a 47.

Výsledky experimentu č. 7:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	5300	-136000	0	0
2	10500	-147100	0	0
3	15700	-151700	0	0
4	20900	-152000	0	0
5	26100	-153300	0	0

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25
0	0	0	0	1	0	1	0	0	0	0	0	1	1	1	0	1	1	1	1	1	0	0	1	1
26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50
0	0	0	0	0	0	0	1	1	1	0	1	0	1	1	0	1	0	1	1	1	0	1	1	0

Ze získaných výsledků vyplývá, že zisk je 153300 Kč, a že k přepravě byly vybrány zásilky: 5,7,13,14,15,17,18,19,20,21,24,25,33,34,35,37,39,40,42,44,45,46,48 a 49.

Výsledky experimentu č. 8:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	5300	-133700	0	0
2	10500	-145200	0	0
3	15700	-148900	0	0
4	20900	-150700	0	0
5	26100	-155600	0	0

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25
0	0	0	0	1	1	0	0	0	0	0	0	1	0	1	0	1	0	1	1	1	1	0	0	1
26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50
0	1	0	0	1	0	0	1	1	1	0	1	0	1	1	0	1	0	0	0	1	1	0	1	0

Ze získaných výsledků vyplývá, že zisk je 155600 Kč, a že k přepravě byly vybrány zásilky: 5,6,13,15,17,19,20,21,22,25,27,30,33,34,35,37,39,40,42,46,47 a 49.

Výsledky experimentu č. 9:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	5300	-140700	0	0
2	10500	-152200	0	0
3	15700	-152200	0	1
4	20900	-159900	0	0
5	26100	-161400	0	0

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25
0	0	0	0	1	1	0	0	0	0	0	0	1	0	1	0	1	1	1	1	0	0	0	1	1
26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50
0	0	0	1	1	0	0	1	1	1	0	1	0	1	1	0	1	0	1	1	1	1	0	0	0

Ze získaných výsledků vyplývá, že zisk je 161400 Kč, a že k přepravě byly vybrány zásilky: 5,6,13,15,17,18,19,20,24,25,29,30,33,34,35,37,39,40,42,44,45,46 a 47.


Výsledky experimentu č. 10:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	5300	-130200	0	0
2	10500	-147800	0	0
3	15700	-150600	0	0
4	20900	-155200	0	0
5	26100	-155200	0	1

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25
0	0	0	0	1	0	0	0	0	0	0	0	1	1	1	0	1	1	1	1	0	0	0	1	1
26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50
1	0	1	1	0	0	0	1	0	1	0	1	0	0	1	0	1	0	1	1	1	1	1	0	0

Ze získaných výsledků vyplývá, že zisk je 155200 Kč, a že k přepravě byly vybrány zásilky: 5,13,14,15,17,18,19,20,24,25,26,28,29,33,35,37,40,42,44,45,46,47 a 48.

Grafické zobrazení shrnutí výsledků úlohy č. 2 je uvedeno na obr. č. 19.



obr. č. 19 Grafické zobrazení shrnutí výsledků úlohy č. 2

Zhodnocení výsledků experimentu

Jak plyne z výsledků jednotlivých experimentů a také z obr. č. 19, optimálního řešení nebylo dosaženo. Nejlepší výsledek byl získán u experimentu č. 4 a nejhorší u experimentu č. 2.

7.5 Řešení úlohy č. 3 - Optimization Tool

V níže uvedené tab. č. 6 jsou uvedeny zvolené parametry výpočtu.

tab. č. 6 Zvolené parametry výpočtu

	Velikost populace	Druh selekce	Druh mutace	Druh křížení
Úloha č. 3	100	uniform	adaptive feasible	single point

Výsledky experimentu č. 1:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	5300	-85100	0	0
2	10500	-91700	0	0
3	15700	-91700	0	1
4	20900	-91700	0	2
5	26100	-91700	0	3

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
0	1	0	1	1	1	1	0	0	1	0	0	1	0	1	0	1	0	0	1

Ze získaných výsledků vyplývá, že zisk je 91700 Kč, a že k přepravě byly vybrány zásilky: 2,4,5,6,7,10,13,15,17 a 20.

Výsledky experimentu č. 2:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	5300	-79800	0	0
2	10500	-88800	0	0
3	15700	-91400	0	0
4	20900	-91400	0	1
5	26100	-91400	0	2

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
0	0	0	1	0	1	0	0	1	1	1	0	1	0	1	0	1	0	1	1

Ze získaných výsledků vyplývá, že zisk je 91400 Kč, a že k přepravě byly vybrány zásilky: 4,6,9,10,11,13,15,17,19 a 20.

Výsledky experimentu č. 3:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	5300	-86900	0	0
2	10500	-86900	0	1
3	15700	-86900	0	2
4	20900	-86900	0	3
5	26100	-90200	0	0

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
0	0	0	0	0	1	1	0	0	0	1	0	1	0	1	0	1	0	1	1

Ze získaných výsledků vyplývá, že zisk je 90200 Kč, a že k přepravě byly vybrány zásilky: 6,7,11,13,15,17,19 a 20.

Výsledky experimentu č. 4:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	5300	-87400	0	0
2	10500	-90400	0	0
3	15700	-90400	0	1
4	20900	-90400	0	2
5	26100	-90400	0	3

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
0	1	0	0	0	1	1	0	1	0	0	0	1	0	1	0	1	0	1	1

Ze získaných výsledků vyplývá, že zisk je 90400 Kč, a že k přepravě byly vybrány zásilky: 2,6,7,9,13,15,17,19 a 20.

Výsledky experimentu č. 5:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	5300	-79600	0	0
2	10500	-86600	0	0
3	15700	-88900	0	0
4	20900	-91900	0	0
5	26100	-91900	0	1

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
0	1	0	1	0	1	0	0	0	1	0	0	1	1	0	1	1	0	1	1

Ze získaných výsledků vyplývá, že zisk je 91900 Kč, a že k přepravě byly vybrány zásilky: 2,4,6,10,13,14,16,17,19 a 20.

Výsledky experimentu č. 6:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	5300	-91300	0	0
2	10500	-91300	0	1
3	15700	-91300	0	2
4	20900	-91300	0	3
5	26100	-91300	0	4

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
0	1	0	0	0	1	1	0	0	0	0	0	1	0	0	1	1	0	1	1

Ze získaných výsledků vyplývá, že zisk je 91300 Kč, a že k přepravě byly vybrány zásilky: 2,6,7,13,16,17,19 a 20.

Výsledky experimentu č. 7:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	5300	-84400	0	0
2	10500	-87300	0	0
3	15700	-88800	0	0
4	20900	-88800	0	1
5	26100	-89000	0	0

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
0	1	0	0	1	1	1	0	1	0	0	0	1	0	0	1	1	0	0	1

Ze získaných výsledků vyplývá, že zisk je 89000 Kč, a že k přepravě byly vybrány zásilky: 2,5,6,7,9,13,16,17 a 20.

Výsledky experimentu č. 8:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	5300	-89400	0	0
2	10500	-89400	0	1
3	15700	-89400	0	2
4	20900	-89400	0	3
5	26100	-90300	0	0

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
0	1	1	0	0	1	0	0	0	0	1	0	1	0	0	1	1	0	1	1

Ze získaných výsledků vyplývá, že zisk je 90300 Kč, a že k přepravě byly vybrány zásilky: 2,3,6,11,13,16,17,19 a 20.

Výsledky experimentu č. 9:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	5300	-86600	0	0
2	10500	-91000	0	0
3	15700	-91000	0	1
4	20900	-91000	0	2
5	26100	-91000	0	3

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
0	1	0	1	0	1	0	0	1	1	0	0	1	1	1	0	1	0	1	1

Ze získaných výsledků vyplývá, že zisk je 91000 Kč, a že k přepravě byly vybrány zásilky: 2,4,6,9,10,13,14,15,17,19 a 20.


Výsledky experimentu č. 10:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	5300	-87400	0	0
2	10500	-89400	0	0
3	15700	-90200	0	0
4	20900	-90200	0	1
5	26100	-90200	0	2

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
0	0	0	0	0	1	1	0	0	0	1	0	1	0	1	0	1	0	1	1

Ze získaných výsledků vyplývá, že zisk je 90200 Kč, a že k přepravě byly vybrány zásilky: 6,7,11,13,15,17,19 a 20.

Grafické zobrazení shrnutí výsledků úlohy č. 3 je uvedeno na obr. č. 20.



obr. č. 20 Grafické zobrazení shrnutí výsledků úlohy č. 3

Zhodnocení výsledků experimentu

Jak plyne z výsledků jednotlivých experimentů a také z obr. č. 20, optimálního řešení nebylo dosaženo. Nejlepší výsledek byl získán u experimentu č. 5 a nejhorší u experimentu č. 7.

8 Výpočetní experimenty

Jelikož v případě úlohy č. 2 a 3 nebylo při zvolených základních parametrech dosaženo optimální řešení bude kapitola 8 věnována výpočetním experimentům s uvedenými dvěma úlohami tak, aby byla získána řešení blížíící se známému optimu. Změnu hodnot výsledků, lze ovlivnit změnou velikosti populace a změnami v dalších parametrech týkajících se selekce, mutace a křížení.

Velikost populace - u velikosti populace se k získání lepšího výsledku doporučuje volit vyšší počet jedinců. To je ovšem omezeno výkonností počítače, který je k dispozici, neboť s přibývajícím počtem jedinců se výpočet zpomaluje. Předem nastavena hodnota velikosti populace byla dvacet.

Selekce - dalším parametrem, kterým lze ovlivnit výsledek, je selekce, kde se dá zadat, jakým způsobem se budou vybírat rodiče pro vznik další generace. Pro připomenutí možnosti typu selekce jsou:

- *stochastic uniform* – náhodný rovnoměrný výběr vzhledem k očekávání,
- *remainder* – deterministický výběr s užitím rulety,
- *uniform* – náhodný výběr z rovnoměrného rozdělení s ohledem na očekávání a počet rodičů,
- *roulette* – simuluje kolo rulety, kde jednotlivá pole odpovídají očekávání jednotlivých segmentů rodičů,
- *tournament* – náhodně vybere určitý počet jedinců a z nich toho nejlepšího.

Mutace - zde se zadává, jakým způsobem bude probíhat mutace. Na výběr jsou tyto možnosti:

- *Gaussian* – na základě Gaussova rozdělení,
- *uniform* – na základě rovnoměrného rozdělení,
- *adaptive feasible* – adaptivně s ohledem na dodržení omezení.

Křížení - k výpočtu se používá populace typu Bit string, tedy k výběru křížení, lze volit jen z následujících možností:

- *scattered* – zobecněné křížení,
- *single point* – jednobodové křížení,
- *two point* – dvoubodové křížení.

V předcházejících úlohách byly zvoleny následující parametry výpočtů, které jsou uvedeny v tabulce č. 7.

tab. č. 7 Zvolené parametry výpočtu předcházejících úloh

Velikost populace	Druh selekce	Druh mutace	Druh křížení
100	uniform	adaptive feasible	single point

Na základě výše uvedených parametrů nastavení výpočtu, byly nabízené prováděné experimenty rozděleny náhodně do 5 skupin experimentů. U každé skupiny budou provedeny 3 výpočty pro jednotlivé úlohy. V níže uvedené tab. č. 8 jsou zobrazena nastavení výpočtu u jednotlivých skupin experimentů.

tab. č. 8 Zobrazení nastavení výpočtu u jednotlivých skupin experimentů

	Velikost populace	Druh selekce	Druh mutace	Druh křížení
Skupina experimentů č.1	250	stochastic uniform	Gaussian	scattered
Skupina experimentů č.2	500	remainder	uniform	single point
Skupina experimentů č.3	750	roulette	adaptive feasible	scattered
Skupina experimentů č.4	1000	tournament	Gaussian	two point
Skupina experimentů č.5	1250	uniform	uniform	single point

8.1 Skupina experimentů č. 1

Pro skupinu experimentů č. 1 bylo zvoleno nastavení výpočtu, které je uvedeno v tab. č. 9.

tab. č. 9 Zobrazení nastavení výpočtu u skupiny experimentů č. 1

	Velikost populace	Druh selekce	Druh mutace	Druh křížení
Skupina experimentů č.1	250	stochastic uniform	Gaussian	scattered

8. 1. 1 Úloha č. 2

Výsledky experimentu č. 1:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	13250	-161600	0	0
2	26250	-162200	0	0
3	39250	-163200	0	0
4	52250	-163200	0	1
5	65250	-163200	0	2

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25
0	0	0	0	1	1	0	0	0	0	0	0	1	0	1	0	1	1	1	1	1	0	0	0	1
26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50
1	0	1	0	0	0	0	1	1	1	0	1	0	1	1	0	1	0	1	0	0	1	0	0	0

Ze získaných výsledků vyplývá, že zisk je 163200 Kč, a že k přepravě byly vybrány zásilky: 5,6,13,15,17,18,19,20,21,25,26,28,33,34,35,37,39,40,42,44 a 47.

Výsledky experimentu č. 2:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	13250	-162500	0	0
2	26250	-163700	0	0
3	39250	-163700	0	1
4	52250	-163700	0	2
5	65250	-163700	0	3

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25
0	0	0	0	1	1	0	0	0	0	0	0	1	0	1	0	1	1	1	1	1	0	0	1	1
26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50
0	0	0	1	0	0	0	1	1	1	0	1	0	1	1	0	1	0	1	0	1	1	0	1	0

Ze získaných výsledků vyplývá, že zisk je 163700 Kč, a že k přepravě byly vybrány zásilky: 5,6,13,15,17,18,19,20,21,24,25,29,33,34,35,37,39,40,42,44,46,47 a 49.

Výsledky experimentu č. 3:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	13250	-161800	0	0
2	26250	-162700	0	0
3	39250	-162700	0	1
4	52250	-163500	0	0
5	65250	-165200	0	0

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25
0	0	0	0	1	1	0	0	0	0	0	0	1	0	1	0	1	1	1	1	1	0	0	0	1
26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50
1	0	0	1	0	0	0	1	0	1	0	1	0	1	1	0	1	0	1	0	1	1	0	0	0

Ze získaných výsledků vyplývá, že zisk je 165200 Kč, a že k přepravě byly vybrány zásilky: 5,6,13,15,17,18,19,20,21,25,26,29,33,35,37,39,40,42,44,46 a 47.

8. 1. 2 Úloha č. 3

Výsledky experimentu č. 1:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	13250	-89000	0	0
2	26250	-89000	0	1
3	39250	-89000	0	2
4	52250	-89000	0	3
5	65250	-89000	0	4

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
0	1	0	0	1	1	1	0	1	0	0	0	1	0	0	1	1	0	0	1

Ze získaných výsledků vyplývá, že zisk je 89000 Kč, a že k přepravě byly vybrány zásilky: 2,5,6,7,9,13,16,17 a 20.

Výsledky experimentu č. 2:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	13250	-91600	0	0
2	26250	-91600	0	1
3	39250	-91600	0	2
4	52250	-91600	0	3
5	65250	-91600	0	4

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
0	1	0	0	1	1	0	0	0	0	1	0	1	0	1	1	1	0	0	1

Ze získaných výsledků vyplývá, že zisk je 91600 Kč, a že k přepravě byly vybrány zásilky: 2,5,6,11,13,15,16,17 a 20.

Výpočet č. 3:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	13250	-82100	0	0
2	26250	-82100	0	1
3	39250	-83100	0	0
4	52250	-83100	0	1
5	65250	-83100	0	2

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
0	0	0	0	1	0	0	0	0	0	0	0	1	0	1	1	1	0	1	1

Ze získaných výsledků vyplývá, že zisk je 83100 Kč, a že k přepravě byly vybrány zásilky: 5,13,15,16,17,19 a 20.

8. 2 Skupina experimentů č. 2

V tab. č. 10 jsou uvedeny parametry nastavení pro skupinu experimentů č. 2.

tab. č. 10 Zobrazení nastavení výpočtu u skupiny experimentů č. 2

	Velikost populace	Druh selekce	Druh mutace	Druh křížení
Skupina experimentů č.2	500	remainder	uniform	single point

8. 2. 1 Úloha č. 2

Výsledky experimentu č. 1:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	26500	-165200	0	0
2	52500	-165200	0	1
3	78500	-165200	0	2
4	104500	-165200	0	3
5	130500	-165200	0	4

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25
0	0	0	0	1	1	0	0	0	0	0	0	1	0	1	0	1	1	1	1	1	0	0	0	1
26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50
1	0	0	1	0	0	0	1	0	1	0	1	0	1	1	0	1	0	1	0	1	1	0	0	0

Ze získaných výsledků vyplývá, že zisk je 165200 Kč, a že k přepravě byly vybrány zásilky: 5,6,13,15,17,18,19,20,21,25,26,29,33,35,37,39,40,42,44,46 a 47.

Výsledky experimentu č. 2:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	26500	-156900	0	0
2	52500	-157500	0	0
3	78500	-157500	0	1
4	104500	-157500	0	2
5	130500	-158000	0	0

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25
0	0	0	0	1	0	1	0	0	0	0	0	1	0	1	0	1	1	1	1	0	0	0	0	1
26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50
1	0	0	1	0	0	0	1	1	1	0	1	0	1	1	0	1	0	1	0	1	1	0	1	0

Ze získaných výsledků vyplývá, že zisk je 158000 Kč, a že k přepravě byly vybrány zásilky: 5,7,13,15,17,18,19,20,25,26,29,33,34,35,37,39,40,42,44,46,47 a 49.

Výsledky experimentu č. 3:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	26500	-162600	0	0
2	52500	-163200	0	0
3	78500	-163200	0	1
4	104500	-163200	0	2
5	130500	-163500	0	0

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25
0	0	0	0	1	1	0	0	0	0	0	0	1	0	1	0	1	1	1	1	1	0	0	0	1
26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50
0	0	1	1	1	0	0	1	1	1	0	1	0	1	1	0	1	0	1	0	1	1	0	1	0

Ze získaných výsledků vyplývá, že zisk je 163500 Kč, a že k přepravě byly vybrány zásilky: 5,6,13,15,17,18,19,20,21,25,28,29,30,33,34,35,37,39,40,42,44,46,47 a 49.

8. 2. 2 Úloha č. 3

Výsledky experimentu č. 1:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	26500	-91600	0	0
2	52500	-91600	0	1
3	78500	-91600	0	2
4	104500	-91600	0	3
5	130500	-91600	0	4

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
0	1	0	0	1	1	0	0	0	0	1	0	1	0	1	1	1	0	0	1

Ze získaných výsledků vyplývá, že zisk je 91600 Kč, a že k přepravě byly vybrány zásilky: 2,5,6,11,13,15,16,17 a 20.

Výsledky experimentu č. 2:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	26500	-86400	0	0
2	52500	-87900	0	0
3	78500	-87900	0	1
4	04500	-87900	0	2
5	130500	-87900	0	3

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
0	0	0	0	1	1	1	0	1	0	1	0	1	0	1	0	1	0	0	1

Ze získaných výsledků vyplývá, že zisk je 87900 Kč, a že k přepravě byly vybrány zásilky: 5,6,7,9,11,13,15,17 a 20.

Výsledky experimentu č. 3:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	26500	-90300	0	0
2	52500	-90300	0	1
3	78500	-90300	0	2
4	104500	-90300	0	3
5	130500	-90300	0	4

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
0	0	0	0	0	1	0	0	1	0	0	0	1	0	1	1	1	0	1	1

Ze získaných výsledků vyplývá, že zisk je 90300 Kč, a že k přepravě byly vybrány zásilky: 6,9,13,15,16,17,19 a 20.

8.3 Skupina experimentů č. 3

Pro výpočet skupiny experimentů č. 3 bylo použito nastavení uvedené v tab. č. 11.

tab. č. 11 Zobrazení nastavení výpočtu u skupiny experimentů č. 3

	Velikost populace	Druh selekce	Druh mutace	Druh křížení
Skupina experimentů č.3	750	roulette	adaptive feasible	scattered

8. 3. 1 Úloha č. 2

Výsledky experimentu č. 1:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	39750	-165200	0	0
2	78750	-165200	0	1
3	117750	-165200	0	2
4	156750	-165200	0	3
5	195750	-165200	0	4

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25
0	0	0	0	1	1	0	0	0	0	0	0	1	0	1	0	1	1	1	1	1	0	0	0	1
26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50
1	0	0	1	0	0	0	1	0	1	0	1	0	1	1	0	1	0	1	0	1	1	0	0	0

Ze získaných výsledků vyplývá, že zisk je 165200 Kč, a že k přepravě byly vybrány zásilky: 5,6,13,15,17,18,19,20,21,25,26,29,33,35,37,39,40,42,44,46 a 47.

Výsledky experimentu č. 2:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	39750	-165200	0	0
2	78750	-165200	0	1
3	117750	-165200	0	2
4	156750	-165200	0	3
5	195750	-165200	0	4

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25
0	0	0	0	1	1	0	0	0	0	0	0	1	0	1	0	1	1	1	1	1	0	0	0	1
26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50
1	0	0	1	0	0	0	1	0	1	0	1	0	1	1	0	1	0	1	0	1	1	0	0	0

Ze získaných výsledků vyplývá, že zisk je 165200 Kč, a že k přepravě byly vybrány zásilky: 5,6,13,15,17,18,19,20,21,25,26,29,33,35,37,39,40,42,44,46 a 47.

Výsledky experimentu č. 3:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	39750	-163700	0	0
2	78750	-163700	0	1
3	117750	-163700	0	2
4	156750	-163700	0	3
5	195750	-163700	0	4

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25
0	0	0	0	1	1	0	0	0	0	0	0	1	0	1	0	1	1	1	1	1	0	0	1	1
26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50
0	0	0	1	0	0	0	1	1	1	0	1	0	1	1	0	1	0	1	0	1	1	0	1	0

Ze získaných výsledků vyplývá, že zisk je 163700 Kč, a že k přepravě byly vybrány zásilky: 5,6,13,15,17,18,19,20,21,24,25,29,33,34,35,37,39,40,42,44,46,47 a 49.

8. 3. 2 Úloha č. 3

Výsledky experimentu č. 1:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	39750	-91900	0	0
2	78750	-91900	0	1
3	117750	-91900	0	2
4	156750	-91900	0	3
5	195750	-91900	0	4

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
0	1	0	1	0	1	0	0	0	1	0	0	1	1	0	1	1	0	1	1

Ze získaných výsledků vyplývá, že zisk je 91900 Kč, a že k přepravě byly vybrány zásilky: 2,4,6,10,13,14,16,17,19 a 20.

Výsledky experimentu č. 2:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	39750	-91800	0	0
2	78750	-91800	0	1
3	117750	-91800	0	2
4	156750	-91800	0	3
5	195750	-91800	0	4

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
0	1	0	1	0	1	0	0	0	0	0	1	1	0	1	0	1	0	1	1

Ze získaných výsledků vyplývá, že zisk je 91800 Kč, a že k přepravě byly vybrány zásilky: 2,4,6,12,13,15,17,19 a 20.

Výsledky experimentu č. 3:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	39750	-91600	0	0
2	78750	-91600	0	1
3	117750	-91600	0	2
4	156750	-91600	0	3
5	195750	-91600	0	4

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
0	1	0	0	1	1	0	0	0	0	1	0	1	0	1	1	1	0	0	1

Ze získaných výsledků vyplývá, že zisk je 91600 Kč, a že k přepravě byly vybrány zásilky: 2,5,6,11,13,15,16,17 a 20.

8. 4 Skupina experimentů č. 4

Pro skupinu experimentů bylo zvoleno nastavení uvedené v tab. č. 12.

tab. č. 12 Zobrazení nastavení výpočtu u skupiny experimentů č. 4

	Velikost populace	Druh selekce	Druh mutace	Druh křížení
Skupina experimentů č.4	1000	tournament	Gaussian	two point

8. 4. 1 Úloha č. 2

Výsledky experimentu č. 1:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	53000	-165200	0	0
2	105000	-165200	0	1
3	157000	-165200	0	2
4	209000	-165200	0	3
5	261000	-165200	0	4

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25
0	0	0	0	1	1	0	0	0	0	0	0	1	0	1	0	1	1	1	1	1	0	0	0	1
26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50
1	0	0	1	0	0	0	1	0	1	0	1	0	1	1	0	1	0	1	0	1	1	0	0	0

Ze získaných výsledků vyplývá, že zisk je 165200 Kč, a že k přepravě byly vybrány zásilky: 5,6,13,15,17,18,19,20,21,25,26,29,33,35,37,39,40,42,44,46 a 47.

Výsledky experimentu č. 2:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	53000	-163600	0	0
2	105000	-163600	0	1
3	157000	-163600	0	2
4	209000	-163600	0	3
5	261000	-163600	0	4

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25
0	0	0	0	1	1	0	0	0	0	0	0	1	0	1	0	1	1	1	1	1	0	0	0	1
26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50
0	0	1	1	0	0	0	1	1	1	0	1	0	1	1	0	1	0	1	1	1	1	0	1	0

Ze získaných výsledků vyplývá, že zisk je 163600 Kč, a že k přepravě byly vybrány zásilky: 5,6,13,15,17,18,19,20,21,25,28,29,33,34,35,37,39,40,42,44,45,46,47 a 49.

Výsledky experimentu č. 3:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	53000	-165200	0	0
2	105000	-165200	0	1
3	157000	-165200	0	2
4	209000	-165200	0	3
5	261000	-165200	0	4

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25
0	0	0	0	1	1	0	0	0	0	0	0	1	0	1	0	1	1	1	1	1	0	0	0	1
26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50
1	0	0	1	0	0	0	1	0	1	0	1	0	1	1	0	1	0	1	0	1	1	0	0	0

Ze získaných výsledků vyplývá, že zisk je 165200 Kč, a že k přepravě byly vybrány zásilky: 5,6,13,15,17,18,19,20,21,25,26,29,33,35,37,39,40,42,44,46 a 47.

8. 4. 2 Úloha č. 3

Výsledky experimentu č. 1:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	53000	-91900	0	0
2	105000	-91900	0	1
3	157000	-91900	0	2
4	209000	-91900	0	3
5	261000	-91900	0	4

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
0	1	0	1	0	1	0	0	0	1	0	0	1	1	0	1	1	0	1	1

Ze získaných výsledků vyplývá, že zisk je 91900 Kč, a že k přepravě byly vybrány zásilky: 2,4,6,10,13,14,16,17,19 a 20.

Výsledky experimentu č. 2:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	53000	-91300	0	0
2	105000	-91300	0	1
3	157000	-91300	0	2
4	209000	-91300	0	3
5	261000	-91300	0	4

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
0	1	0	0	0	1	1	0	0	0	0	0	1	0	0	1	1	0	1	1

Ze získaných výsledků vyplývá, že zisk je 91600 Kč, a že k přepravě byly vybrány zásilky: 2,6,7,13,16,17,19 a 20.

Výsledky experimentu č. 3:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	53000	-91600	0	0
2	105000	-91600	0	1
3	157000	-91600	0	2
4	209000	-91600	0	3
5	261000	-91600	0	4

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
0	1	0	0	1	1	0	0	0	0	1	0	1	0	1	1	1	0	0	1

Ze získaných výsledků vyplývá, že zisk je 91600 Kč, a že k přepravě byly vybrány zásilky: 2,5,6,11,13,15,16,17 a 20.

8.5 Skupina experimentů č. 5

V tab. č. 13 je zobrazeno nastavení výpočtu pro skupinu experimentů č. 5.

tab. č. 13 Zobrazení nastavení výpočtu u skupiny experimentů č. 5

	Velikost populace	Druh selekce	Druh mutace	Druh křížení
Skupina experimentů č.5	1250	uniform	uniform	single point

8. 5. 1 Úloha č. 2

Výsledky experimentu č. 1:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	66250	-144800	0	0
2	131250	-153100	0	0
3	196250	-154100	0	0
4	261250	-154100	0	1
5	326250	-154100	0	2

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25
0	0	0	0	1	1	0	0	0	0	0	0	1	0	1	0	1	0	1	1	0	1	0	0	1
26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50
0	0	1	0	1	0	0	1	1	1	0	1	1	1	1	1	1	0	1	1	0	1	1	0	0

Ze získaných výsledků vyplývá, že zisk je 154100 Kč, a že k přepravě byly vybrány zásilky: 5,6,13,15,17,19,20,22,25,28,30,33,34,35,37,38,39,40,41,42,44,45,47 a 48.

Výsledky experimentu č. 2:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	66250	-140500	0	0
2	131250	-150500	0	0
3	196250	-150500	0	1
4	261250	-150900	0	0
5	326250	-154800	0	0

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25
0	0	0	0	1	1	0	0	0	1	0	0	1	0	1	0	1	1	1	1	0	0	0	1	1
26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50
0	0	1	0	1	0	0	1	0	1	0	0	0	1	1	0	1	0	0	1	1	1	1	1	0

Ze získaných výsledků vyplývá, že zisk je 154800 Kč, a že k přepravě byly vybrány zásilky: 5,6,10,13,15,17,18,19,20,24,25,28,30,33,35,39,40,42,45,46,47,48 a 49.

Výsledky experimentu č. 3:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	66250	-136400	0	0
2	131250	-141600	0	0
3	196250	-155900	0	0
4	261250	-156500	0	0
5	326250	-156500	0	1

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25
0	1	0	0	1	1	0	0	0	1	0	0	1	1	1	0	1	1	1	1	1	0	0	0	1
26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50
0	0	0	0	0	0	0	1	1	0	0	1	0	0	1	0	1	0	1	1	1	1	1	0	0

Ze získaných výsledků vyplývá, že zisk je 156500 Kč, a že k přepravě byly vybrány zásilky: 2,5,6,10,13,,14,15,17,18,19,20,21,25,33,34,37,40,42,44,45,46,47 a 48.

8. 5. 2 Úloha č. 3

Výsledky experimentu č. 1:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	66250	-90400	0	0
2	131250	-90400	0	1
3	196250	-91800	0	0
4	261250	-91800	0	1
5	326250	-91800	0	2

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
0	1	0	1	0	1	0	0	0	0	0	1	1	0	1	0	1	0	1	1

Ze získaných výsledků vyplývá, že zisk je 91800 Kč, a že k přepravě byly vybrány zásilky: 2,4,6,12,13,15,17,19 a 20.

Výsledky experimentu č. 2:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	66250	-91400	0	0
2	131250	-91800	0	0
3	196250	-91800	0	1
4	261250	-91800	0	2
5	326250	-91800	0	3

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
0	1	0	1	0	1	0	0	0	0	0	1	1	0	1	0	1	0	1	1

Ze získaných výsledků vyplývá, že zisk je 91800 Kč, a že k přepravě byly vybrány zásilky: 2,4,6,12,13,15,17,19 a 20.


Výsledky experimentu č. 3:

Generation	f-count	Best f(x)	max constraint	Stall Generations
1	66250	-91900	0	0
2	131250	-91900	0	1
3	196250	-91900	0	2
4	261250	-91900	0	3
5	326250	-91900	0	4

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
0	1	0	1	0	1	0	0	0	1	0	0	1	1	0	1	1	0	1	1

Ze získaných výsledků vyplývá, že zisk je 91900 Kč, a že k přepravě byly vybrány zásilky: 2,4,6,10,13,14,16,17,19 a 20.

Grafické zobrazení shrnutí výsledků úloh č. 2 a 3 ve výpočetní části je uvedeno na obr. č. 21 a obr. č. 22.




obr. č. 21 Grafické zobrazení shrnutí výsledků skupiny experimentů úlohy č. 2

Zhodnocení výsledků experimentu

Jak plyne z výsledků jednotlivých experimentů a také z obr. č. 21, optimálního řešení bylo dosaženo u čtyřech z pěti skupin experimentů, a to u skupiny experimentů

č. 1, 2, 3, 4. Nejhorší výsledky byly získány v případě skupiny experimentů č. 5. Z grafického shrnutí výsledků je patrné, že 40% výsledků dosahuje optima.



obr. č. 22 Grafické zobrazení shrnutí výsledků skupiny experimentů úlohy č. 3

Zhodnocení výsledků experimentu

Z výsledků jednotlivých experimentů a také z obr. č. 22, je zřejmé, že optimálního řešení nebylo dosaženo ani u jedné skupiny experimentů. Nejlepší dosažený výsledek je 91900 Kč, který byl získán u experimentů č. 7, 10 a 15. Za to nejhoršího výsledku bylo dosaženo u experimentu č. 3.

9 Zhodnocení dosažených výsledků a jejich porovnání s výsledky dosaženými exaktní metodou

Genetické algoritmy jsou nástrojem pro podporu rozhodování u celé řady úloh teoretického i výrazně aplikačního charakteru. Používají se zejména v situacích, kdy exaktní metody selhávají, nebo je není možno z různých důvodů použít. Genetické algoritmy spadají pod heuristické metody, tedy metody přibližné. V tomto případě není zaručeno, zda bylo dosaženo optimálního řešení, což je řešení, které za daných vstupních podmínek je nejlépe vyhovující.

V případě použití jakékoliv heuristické metody (tedy i GA) je na místě výzkum v oblasti přesnosti získaných výsledků. Tento výzkum je však obtížné, ne-li nemožné, realizovat analyticky, zbývá tedy pouze úroveň experimentální. Experimentální testovací metody (tedy i GA) je možné provádět prostřednictvím změn hodnot parametrů výpočtu a testování odchýlení výsledků od optimálního řešení (je-li známo). Tímto způsobem se postupuje i v odborné literatuře, přičemž výsledkem je pravidlo konstatování, které říká jak dobré výsledky dala heuristická metoda s konkrétními parametry v určitém procentu případů. Z těchto výsledků se následně usuzuje na vhodnost použití dané metody k řešení určitého typu problému.

Proto bylo cílem diplomové práce bylo porovnat výsledky úloh získané genetickými algoritmy s výsledky získanými exaktní metodou.

Vyřešené úlohy exaktní metodou pomocí softwaru Xpress-IVE jsou uvedeny v šesté kapitole. Z výsledků úlohy č. 1, je patrné, že optimální výsledek činí 107 700Kč. V úloze č. 2 je optimální výsledek 165 200Kč a v poslední 3. úloze, bylo dosaženo optimálního řešení 92 700Kč.

Řešené úlohy heuristickou metodou pomocí genetických algoritmů v softwaru Matlab jsou uvedeny v sedmé a osmé kapitole. Jak již bylo uvedeno jedná se o přibližnou metodu, tedy k získání přesnějších výsledků byla každá úloha vyřešena 10x. Z těchto výsledků uvedených v kapitole č. 7, bylo získáno již optimální řešení u úlohy č. 1 při kombinaci parametrů: velikost populace = 100, typ selekce - *uniform*, typ mutace - *adaptive feasible*, a typ křížení – *single point*. U ostatních úloh nebylo optimálního řešení dosaženo. V úloze č. 2 bylo docíleno nejlepšího výsledku 163 100Kč a v třetí úloze 91 900Kč.


Osmá kapitola byla věnována experimentům s úlohami č. 2 a 3, kde se měnily hodnoty parametrů v rámci optimalizačního algoritmu. Z těchto výsledků je patrné, že u úlohy č. 2 bylo získáno optimální řešení, tedy zisk 165 200Kč, a to při kombinaci parametrů: velikost populace = 500, typ selekce - *remainder*, typ mutace - *uniform*, a typ křížení – *single point*.. V poslední úloze nebylo ani při změnách parametrů dosaženo optimálního výsledku, nejlepší získaný výsledek činí stále 91 900Kč. Souhrnný přehled výsledků v rámci prováděných experimentů je uveden v tab. č. 14.

tab. č. 14 Průměrná odchylka od optima při použití GA

i	Parametry experimentů				Ø odchylka [Kč]		
	Velikost populace	Typ selekce	Typ mutace	Typ křížení	Úloha č.1	Úloha č.2	Úloha č.3
1	100	uniform	adaptive feasible	single point	480	8280	1870
2	250	stochastic uniform	Gaussian	scattered	-	1166,7	4800
3	500	remainder	uniform	single point	-	2966,7	2766,7
4	750	roulette	adaptive feasible	scattered	-	500	933,3
5	1000	tournamet	Gaussian	two point	-	533,3	1000
6	1250	uniform	uniform	single point	-	10066,7	866,7

V případě úlohy č. 1 bylo GA dosaženo optima již v základní skupině experimentů. Přesto je v příslušném řádku tabulky uvedena odchylka 480 Kč. Uvedená odchylka vznikla v důsledku skutečnosti, že optima bylo dosaženo pouze v 4 z 10-ti případů. Co se týče úloh č. 2 a 3, jsou hodnoty průměrných odchylek od optima při základním nastavení parametrů výpočtu poměrně značné. Z tohoto důvodu byly prováděny další skupiny experimentů. V případě úlohy č. 2 bylo dosaženo nejlepších výsledků z pohledu průměrné odchylky u 4. skupině experimentů. Průměrná odchylka od optimálního řešení činila 500 Kč, jednalo se o kombinaci parametrů – velikost populace 750, typ selekce *roulette*, typ mutace *adaptive feasible*, typ křížení *scattered*. V případě úlohy č. 3 bylo dosaženo nejlepších výsledků z pohledu průměrné odchylky u 6. skupiny experimentů. Průměrná odchylka od optimálního řešení činila 866,7 Kč při kombinaci parametrů – velikost populace 1250, typ selekce *uniform*, typ mutace *uniform*, typ křížení *single point*.

Grafické zobrazení porovnání výsledků získané exaktní a heuristickou metodou je uvedeno na obr. č. 23.



obr. č. 23 Grafické zobrazení porovnání výsledků získané exaktní a heuristickou metodou

10 Závěr

Předložená diplomová práce je věnována aplikaci genetických algoritmů na úlohu o plánování rozvozu zásilek v dopravní síti.

Úvodní část diplomové práce, se zabývá genetickými algoritmy, kde jsou uvedeny základní pojmy GA, genetické operátory, činnost genetických algoritmů a jejich výhody a nevýhody.

Následující kapitola popisuje postavení genetických algoritmů v hierarchii optimalizačních metod.

Typologie problémů řešených genetickými algoritmy je popsána v následující části diplomové práce, kde je uvedeno několik příkladů využití genetických algoritmů a to jak ve strojírenství, stavebnictví, energetice, tak v silniční dopravě.

V navazující kapitole jsou sestaveny matematické modely tří typů úloh o plánování rozvozu zásilek v dopravní síti, v dalších kapitolách, jsou tyto úlohy vyřešeny exaktně pomocí softwaru Xpress-IVE a s genetickými algoritmy v softwaru Matlab.

Úlohy, u nichž nebylo při použití GA dosaženo optima, byly následně podrobeny dalším experimentům, při kterých byly měněny parametry optimalizačního výpočtu.

Závěrečná část diplomové práce popisuje dosažené výsledky.

Seznam použité literatury:

- [1] HYNEK, J.: *Genetické algoritmy a genetické programování*. Praha: Grada Publishing. 2008. 182 s. ISBN 978-80-247-2695-3
- [2] ZELINKA, I.; OPLÁTKOVÁ, Z.; ŠEDÁ, M.; OŠMERA, P.; VČELAŘ, F.: *Evoluční výpočetní techniky*. Praha: BEN – technická literatura . 2008. 536 s. ISBN 978-80-7300-218-3
- [3] POKORNÝ, Pavel. *Využití optimalizace v řízení výroby*. Brno, 2008. Diplomová práce. VUT Brno. Dostupné z:
http://www.vutbr.cz/www_base/zav_prace_soubor_verejne.php?file_id=6336
- [4] PAAR, Martin. *Využití genetických algoritmů při optimalizaci procesů v energetice*. Brno, 2009. Diplomová práce. VUT Brno. Dostupné z:
http://www.vutbr.cz/www_base/zav_prace_soubor_verejne.php?file_id=20676.
- [5] *Genetické algoritmy*. In: [online]. [cit. 2012-04-11]. Dostupné z:
<http://poli.cs.vsb.cz/edu/isy/down/ga.pdf>
- [6] RAMACHANDRAN, Naveen. Accident Emergency Response And Routing Software (AERARS) using Genetic Algorithm. In: <Http://www.enggjournals.com> [online]. [cit. 2012-04-11]. Dostupné z:
<http://www.enggjournals.com/ijcse/doc/IJCSE11-03-07-016.pdf>
- [7] WANG, JiaMei. Bus dispatching optimization based on genetic algorithm. In: <Http://ieeexplore.ieee.org> [online]. [cit. 2012-04-11]. Dostupné z:
http://ieeexplore.ieee.org/xpl/login.jsp?tp=&arnumber=5514792&url=http%3A%2F%2Fieeexplore.ieee.org%2Fxppls%2Fabs_all.jsp%3Farnumber%3D5514792
- [8] TEDA, Jaroslav. Genetické algoritmy a jejich aplikace v praxi. In: <Http://programujte.com> [online]. 2005 [cit. 2012-04-11]. Dostupné z:
<http://programujte.com/clanek/2005072601-geneticke-algoritmy-a-jejich-aplikace-v-praxi/>
- [9] SLIVONĚ, Miroslav. SOFTWARE PRO SESTAVU OKRUŽNÍCH JÍZD. In: [online]. 2010 [cit. 2012-04-11]. Dostupné z:
http://pernerscontacts.upce.cz/19_2010/Slivone.pdf

- [10] W. PEARSON, David. *Artificial Neural Nets and Genetic Algorithms*. Austria: Springer Verlag Gmbh, 2003. ISBN 3-211-00743-1. Dostupné z: http://books.google.cz/books?id=3haO5vOc12cC&pg=PA260&lpg=PA260&dq=genetic+algorithm+road+transport&source=bl&ots=xGqa06bd25&sig=IT9dK5Izdtl2zoEmVLMF11YGJMg&hl=cs&ei=2GNFTeeCOoXusgaHtaTFDg&sa=X&oi=book_result&ct=result&resnum=1&ved=0CB8Q6AEwAA#v=onepage&q=genetic%20algorithm%20road%20transport&f=false
- [11] KUMAR, A. John Sanjeev. Intelligent Transport Route Planning Using Genetic Algorithms in Path Computation Algorithms. In: *Http://www.eurojournals.com* [online]. 2009 [cit. 2012-04-11]. Dostupné z: http://www.eurojournals.com/ejsr_25_3_11.pdf
- [12] PAKNIAT, Parinaz. *Optimizing Bridge Decks Maintenance Strategies Based on Probabilistic Performance Prediction Using Genetic Algorithm*. Canada: Concordia University, 2008. ISBN 0494454970.
- [13] POSPĚCH, Lukáš. *Návrh matematického modelu distribučního systému*. Ostrava, 2009. Bakalářská práce. VŠB - TUO.

Seznam obrázků:

- obr. č. 1 Jednobodové křížení
- obr. č. 2 Vícebodové křížení
- obr. č. 3 Operátor mutace
- obr. č. 4 Schématické znázornění průběhu genetického algoritmu
- obr. č. 5 Hierarchie optimalizačních metod
- obr. č. 6 Pracovní prostředí optimalizačního software Xpress-IVE
- obr. č. 7 M-file k vytvoření fitness funkce
- obr. č. 8 M-file k vytvoření omezujících podmínek
- obr. č. 9 M-file přes který se provádí výpočet
- obr. č. 10 Okno nástroje gatool softwaru Matlab
- obr. č. 11 Hodnota fitness funkce v jednotlivých generacích
- obr. č. 12 Histogram skóre jednotlivých jedinců dané generace
- obr. č. 13 Úroveň kritérií pro ukončení výpočtu
- obr. č. 14 Hodnota fitness funkce jednotlivých jedinců dané generace
- obr. č. 15 Hodnota fitness funkce nejlepšího, nejhoršího jedince a střední hodnota
- obr. č. 16 Export výsledků do pracovní plochy
- obr. č. 17 Zobrazení výsledků
- obr. č. 18 Grafické zobrazení shrnutí výsledků úlohy č. 1
- obr. č. 19 Grafické zobrazení shrnutí výsledků úlohy č. 2
- obr. č. 20 Grafické zobrazení shrnutí výsledků úlohy č. 3
- obr. č. 21 Grafické zobrazení shrnutí výsledků skupiny experimentů úlohy č. 2
- obr. č. 22 Grafické zobrazení shrnutí výsledků skupiny experimentů úlohy č. 3
- obr. č. 23 Grafické zobrazení porovnání výsledků získané exaktní a heuristickou metodou

Seznam tabulek:

- tab. č. 1 Zadané hodnoty pro úlohu o plánování rozvozu zásilek v dopravní síti č. 1
- tab. č. 2 Zadané hodnoty pro úlohu o plánování rozvozu zásilek v dopravní síti č. 2
- tab. č. 3 Zadané hodnoty pro úlohu o plánování rozvozu zásilek v dopravní síti č. 3
- tab. č. 4 Zvolené parametry výpočtu
- tab. č. 5 Zvolené parametry výpočtu
- tab. č. 6 Zvolené parametry výpočtu
- tab. č. 7 Zvolené parametry výpočtu předcházejících úloh
- tab. č. 8 Zobrazení nastavení výpočtu u jednotlivých skupin experimentů
- tab. č. 9 Zobrazení nastavení výpočtu u skupiny experimentů č. 1
- tab. č. 10 Zobrazení nastavení výpočtu u skupiny experimentů č. 2
- tab. č. 12 Zobrazení nastavení výpočtu u skupiny experimentů č. 4
- tab. č. 13 Zobrazení nastavení výpočtu u skupiny experimentů č. 5
- tab. č. 14 Průměrná odchylka od optima při použití GA